

Pós-graduação em Ciência da Computação  
Centro de Informática  
Universidade Federal de Pernambuco

# **Redes Convolucionais Aplicadas em Visão Computacional**

Marcos José Canêjo Estevão de Azevêdo

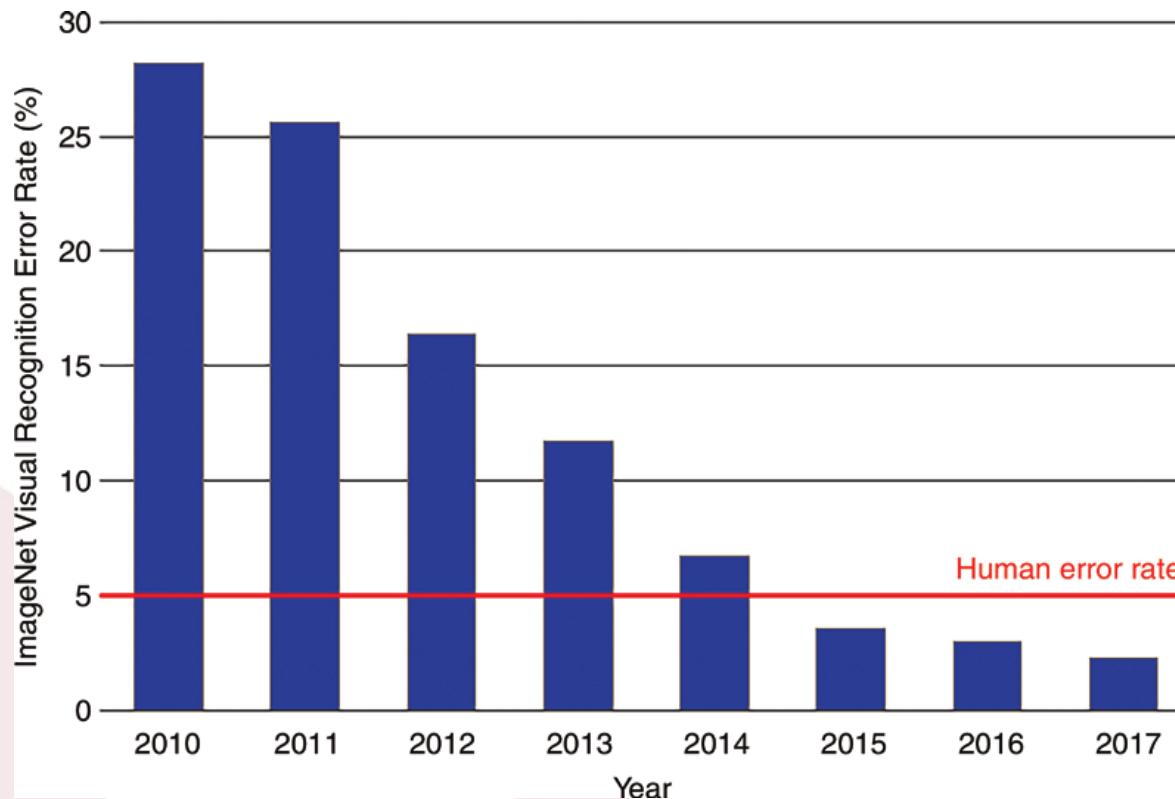
[mjcea@cin.ufpe.br](mailto:mjcea@cin.ufpe.br)

# Sumário

- História
- Evolução
- Tipos
- Aplicações
- Considerações Finais

# História

- Em 2012 ganharam destaque após ganhar a competição ImageNet Large-Scale Visual Recognition Challenge.



# História



Zebra (13.74%)



Dálmata (40.86%)



Banco de Parque (19.35%)



Zebra (26.31%)



Zebra (40.19%)

# Evolução



# Evolução

Corpo branco  
em forma oval



Cabeça arredondada  
e alongada com  
uma protuberância  
laranja

Pescoço branco e  
longo em forma  
retangular

# Evolução

Cabeça arredondada e alongada com protuberância preta



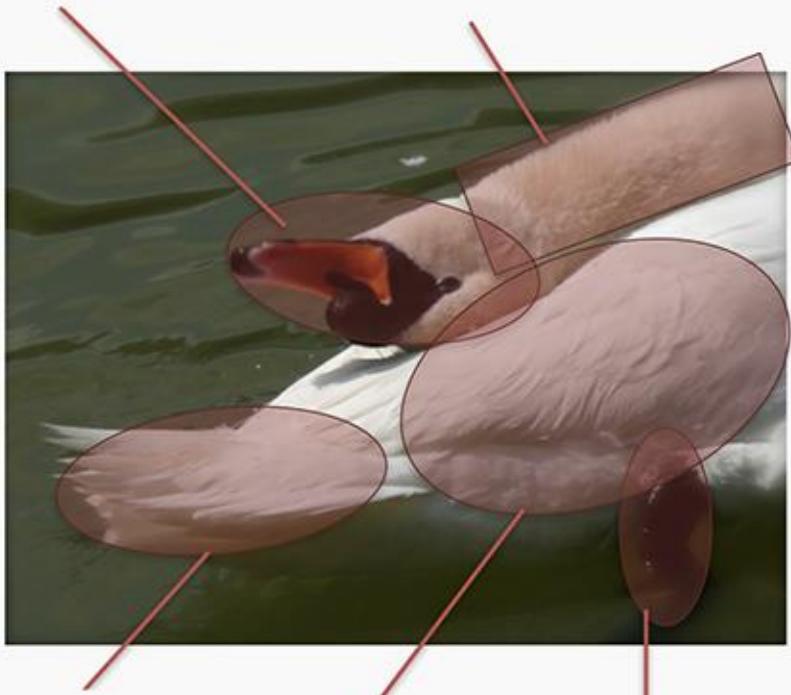
Corpo branco em forma oval com ou sem asas simétricas grandes

Pescoço branco e longo em forma retangular

# Evolução

Cabeça arredondada e alongada com protuberância preta ou laranja invertida

Pescoço branco e longo em forma retangular que pode se curvar, não sendo necessariamente reto



Cauda branca geralmente longe da cabeça

Asas visíveis

Pés pretos geralmente com formas diferentes

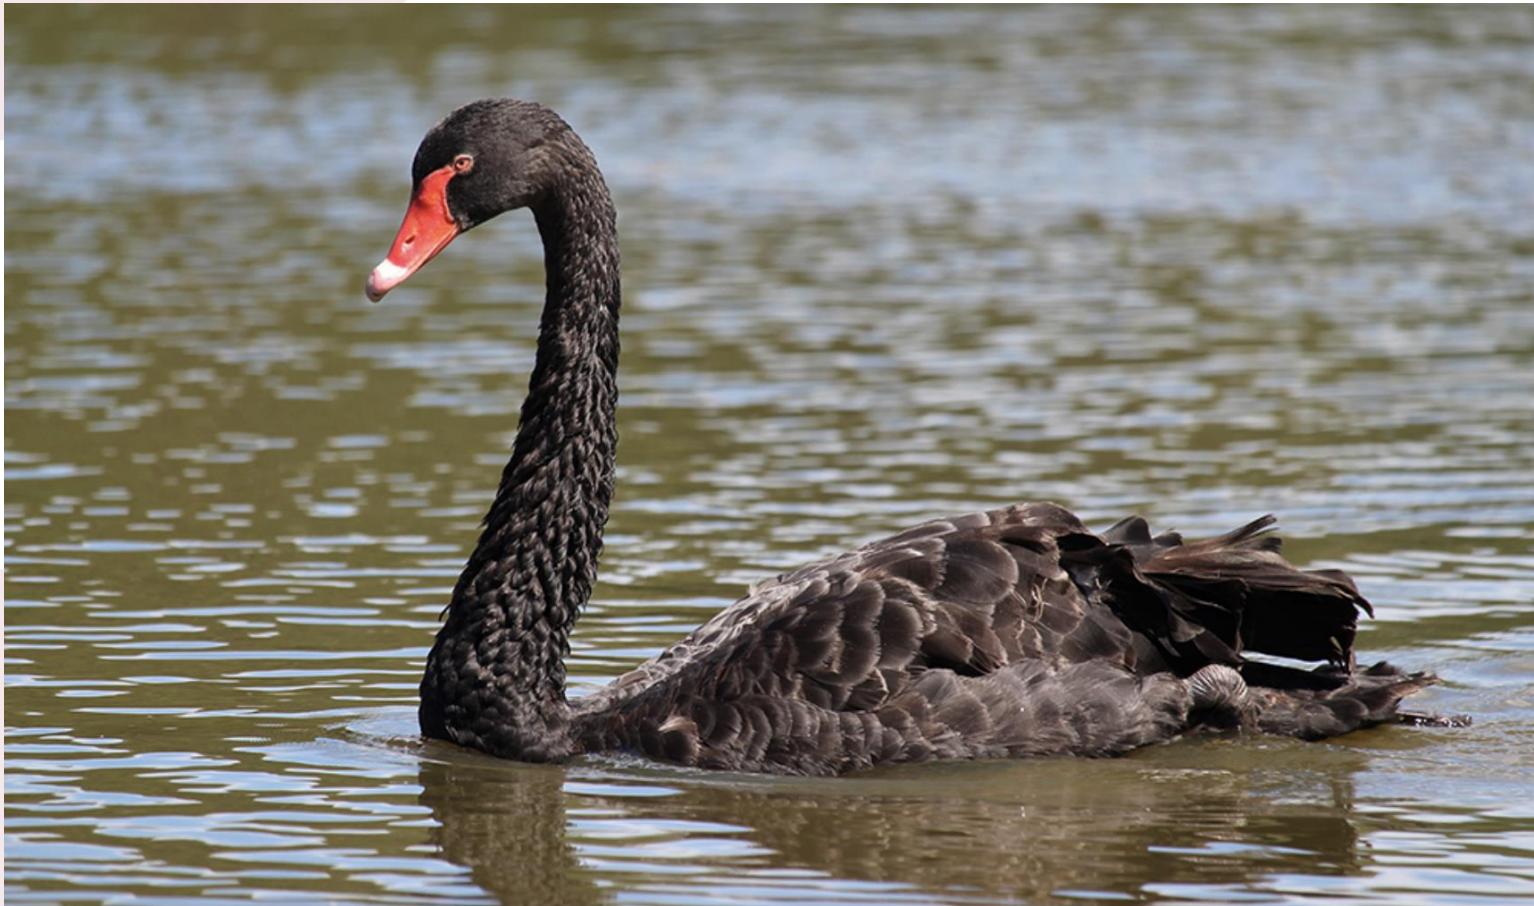
Olhos pretos circulares que podem ou não aparecer na câmera simultaneamente



Pescoço com forma oval



# Evolução



# Evolução

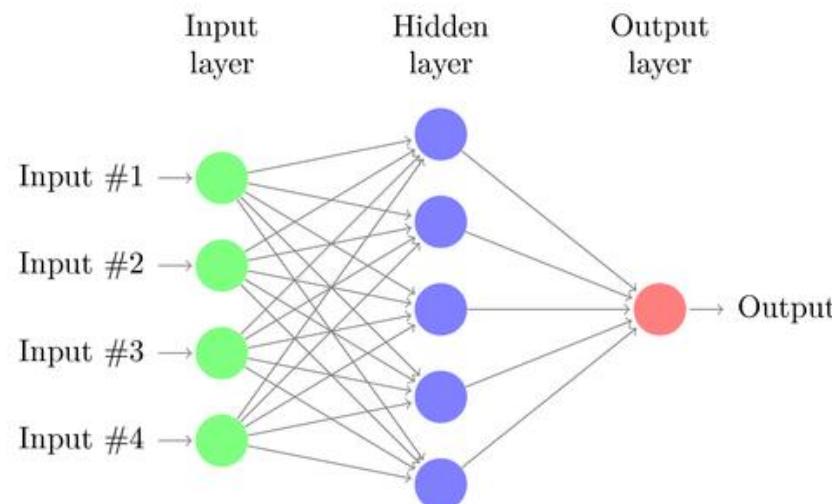


Homem em uma tenda de cisne tentando fotografar cisnes

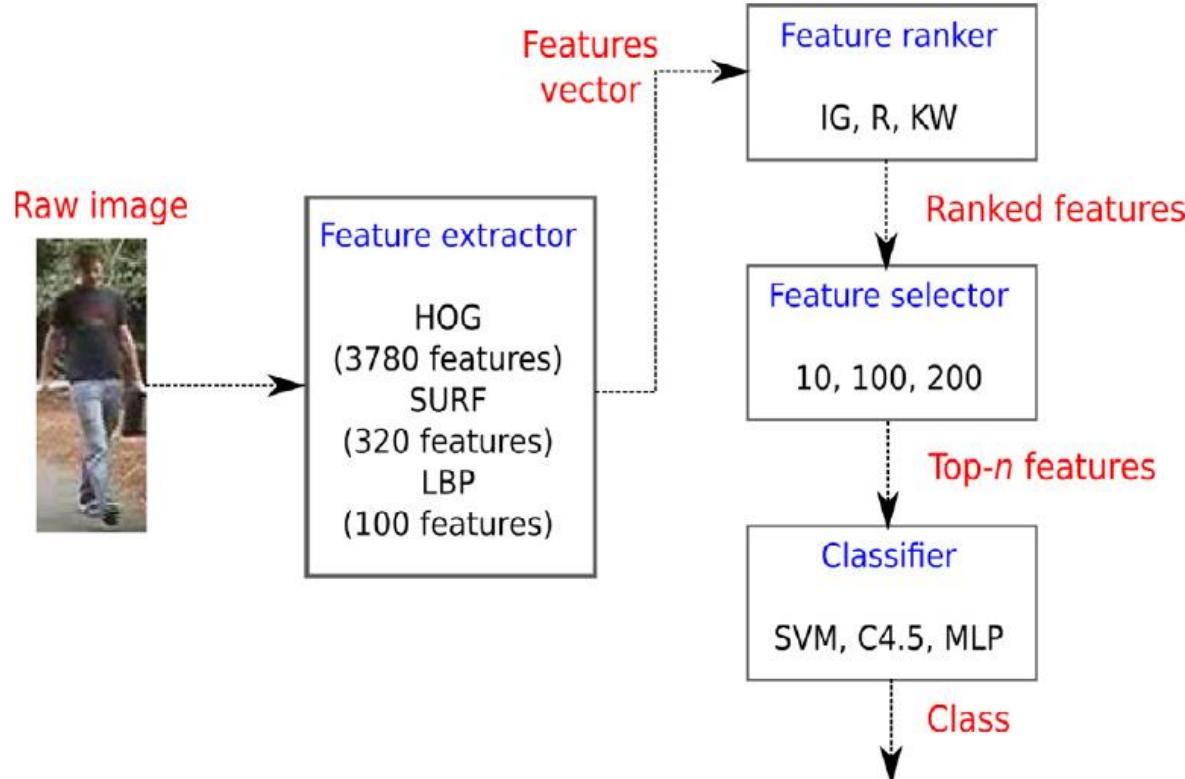


## EXTRAÇÃO DE CARACTERÍSTICAS

→ SIFT, FAST, SURF,  
HOG, LBP e etc.

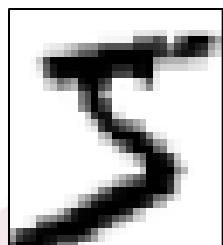


# Evolução

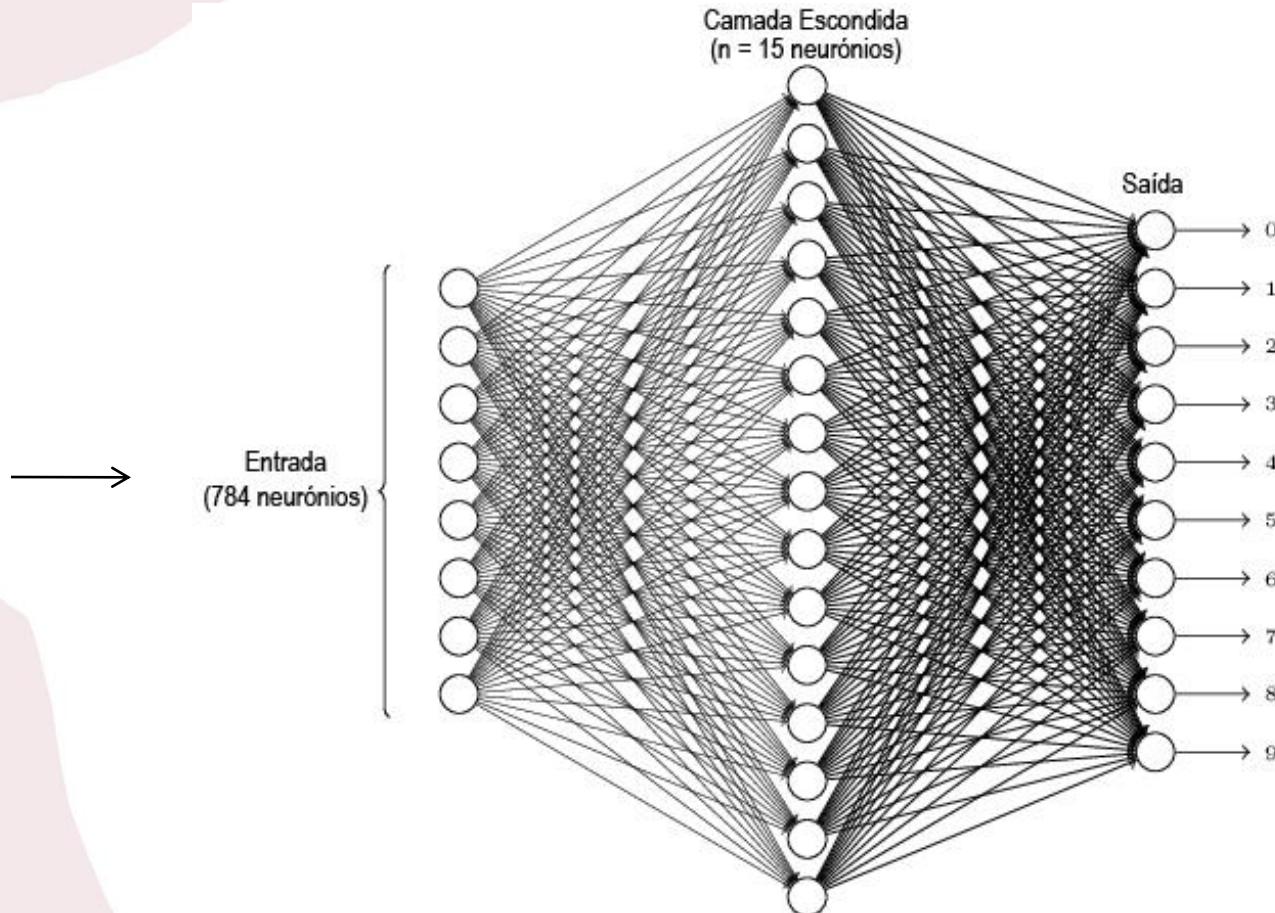


**Fig. 2.** Hand-designed feature extraction and classification process.

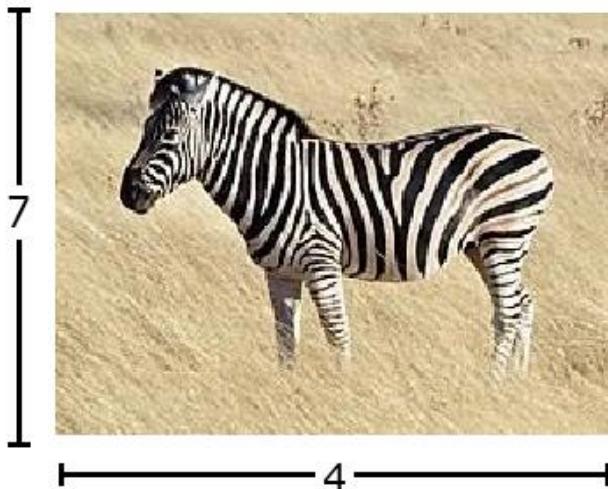
# Evolução



28x28 pixels



# Evolução



		165	187	209	7
	14	125	201	98	159
253	144	120	41	147	204
67	100	32	23	165	30
209	118	124	59	201	79
210	236	105	19	218	156
35	178	199	4	14	218
115	104	34	19	196	
32	69	231	74		

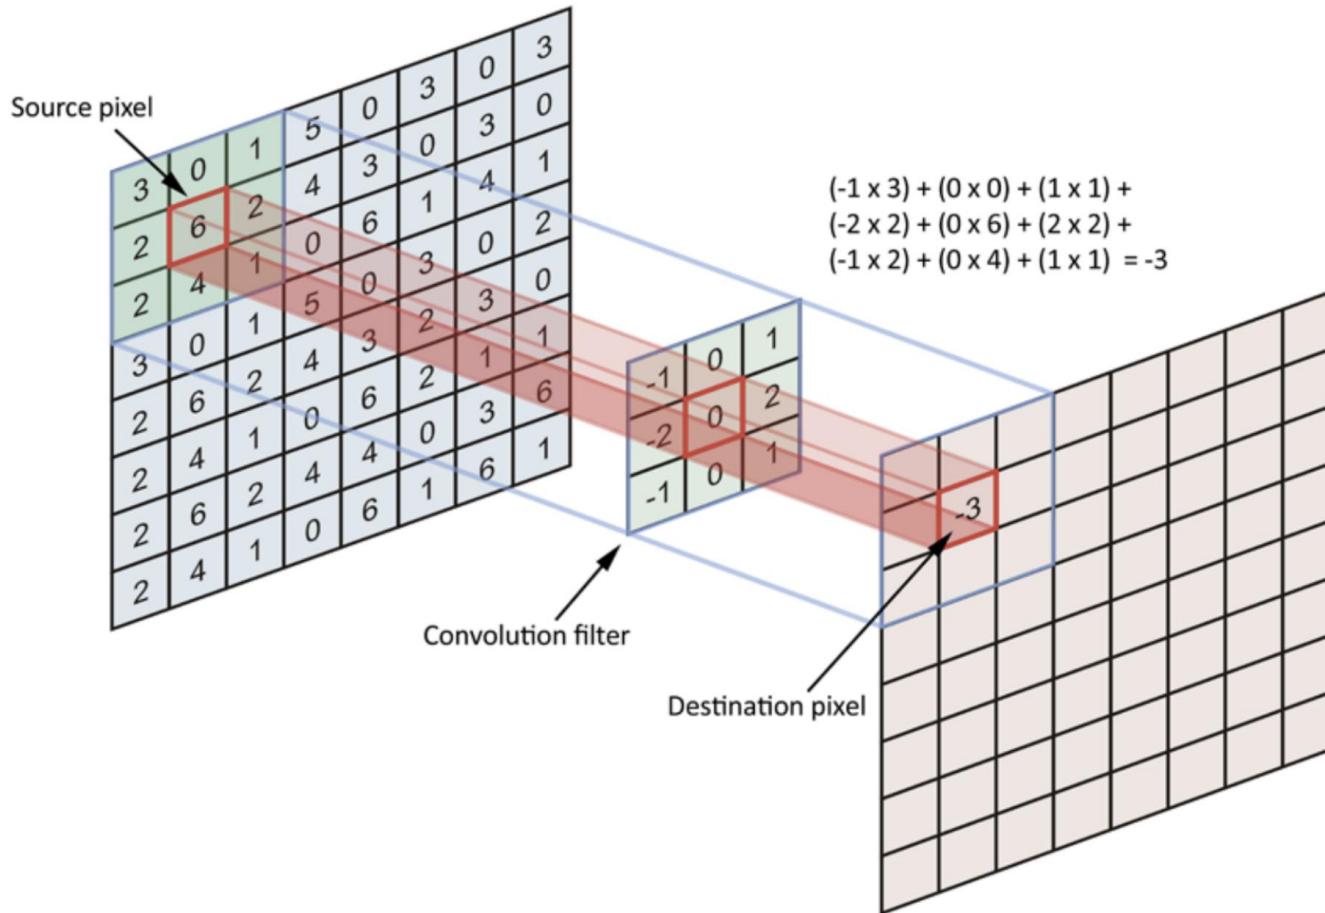
# Evolução



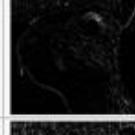
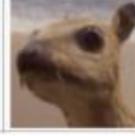
Os pixels próximos são mais fortemente relacionados que os distantes.

Objetos são construídos a partir de partes menores.

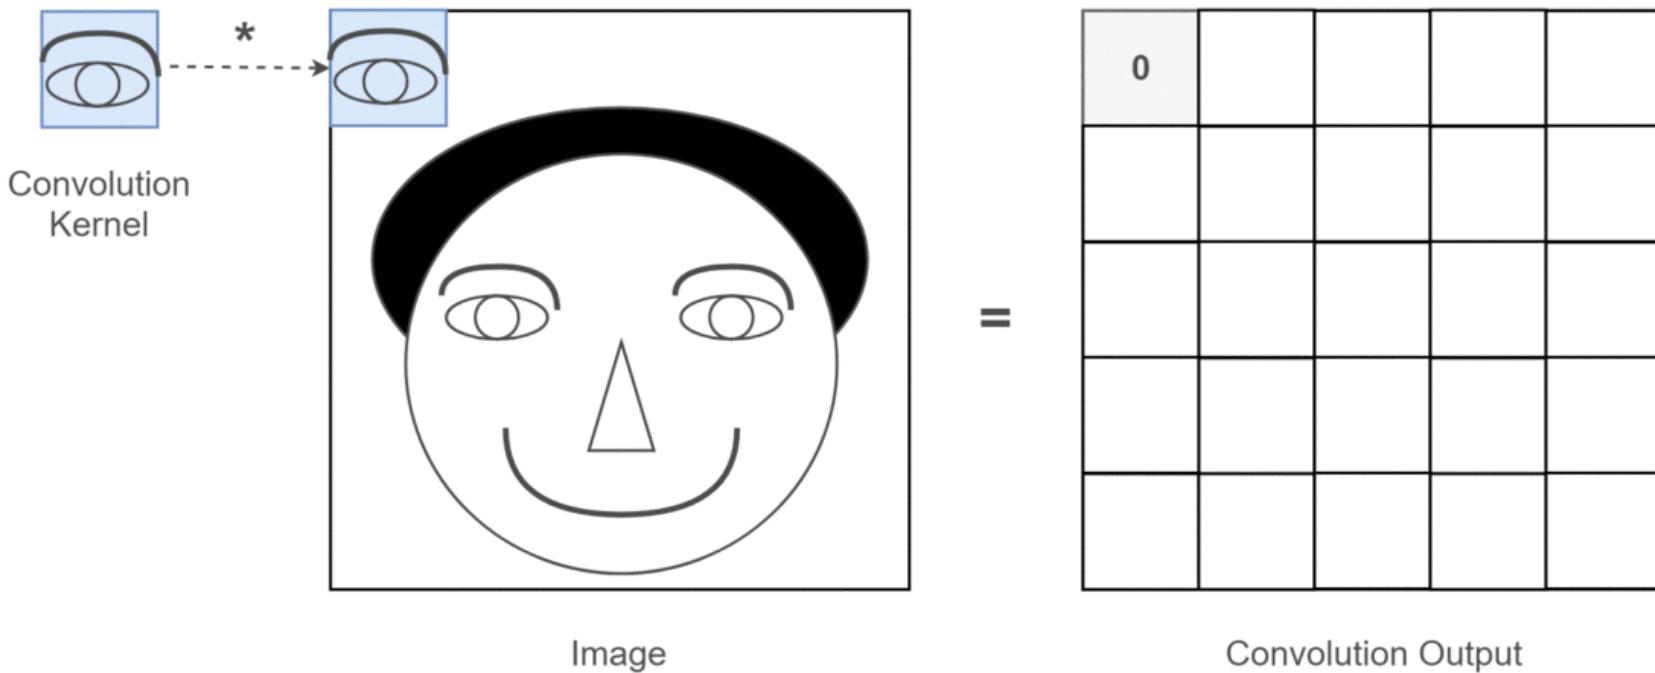
# Convolução



# Convolução

Operation	Filter	Convolved Image
Identity	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
Edge detection	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
Sharpen	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
Box blur (normalized)	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	
Gaussian blur (approximation)	$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$	

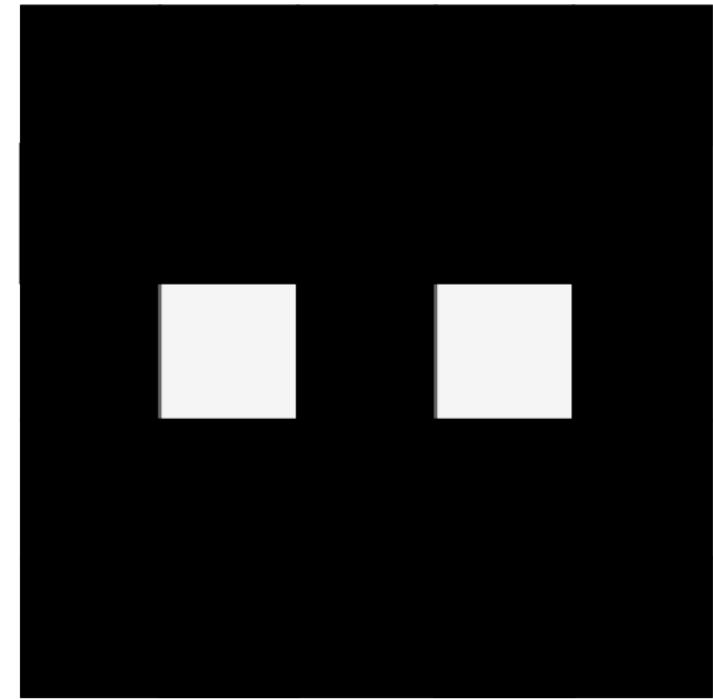
# Convolução



# Convolução

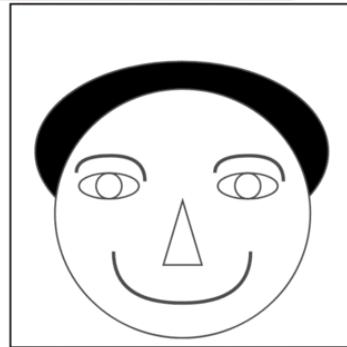
0	0	0	0	0
0	0	0	0	0
0	100	0	100	0
0	0	0	0	0
0	0	0	0	0

Convolution Output

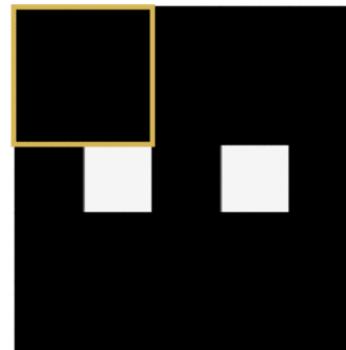


Convolution Output  
(as an Image)

# Pooling



Image

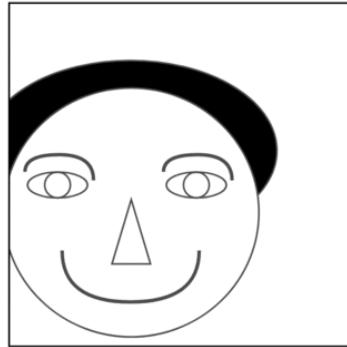


Convolution Output  
(as an Image)

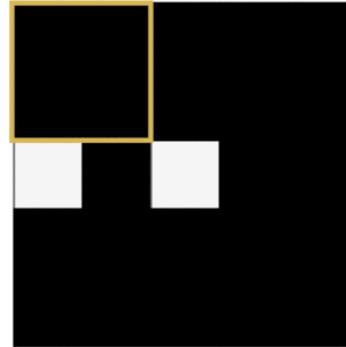


Pooling Output (as  
an Image)

Same image as above but  
translated on x-axis



Image



Convolution Output  
(as an Image)



Pooling Output (as  
an Image)

# Convolução

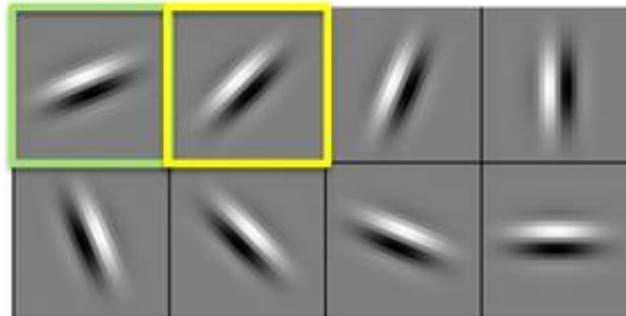


Input

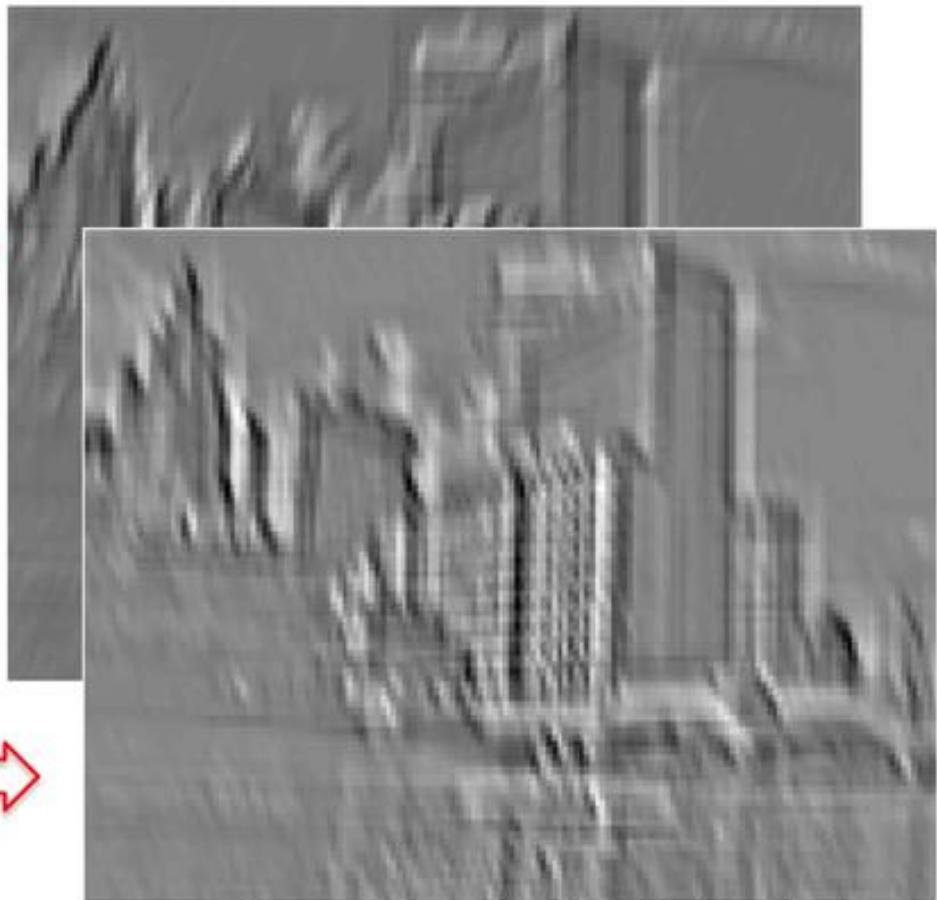
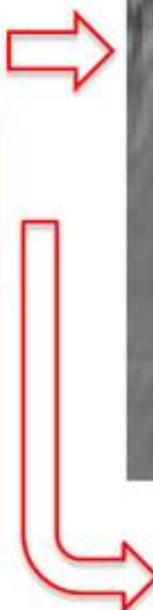
# Convolução



Imagen de entrada



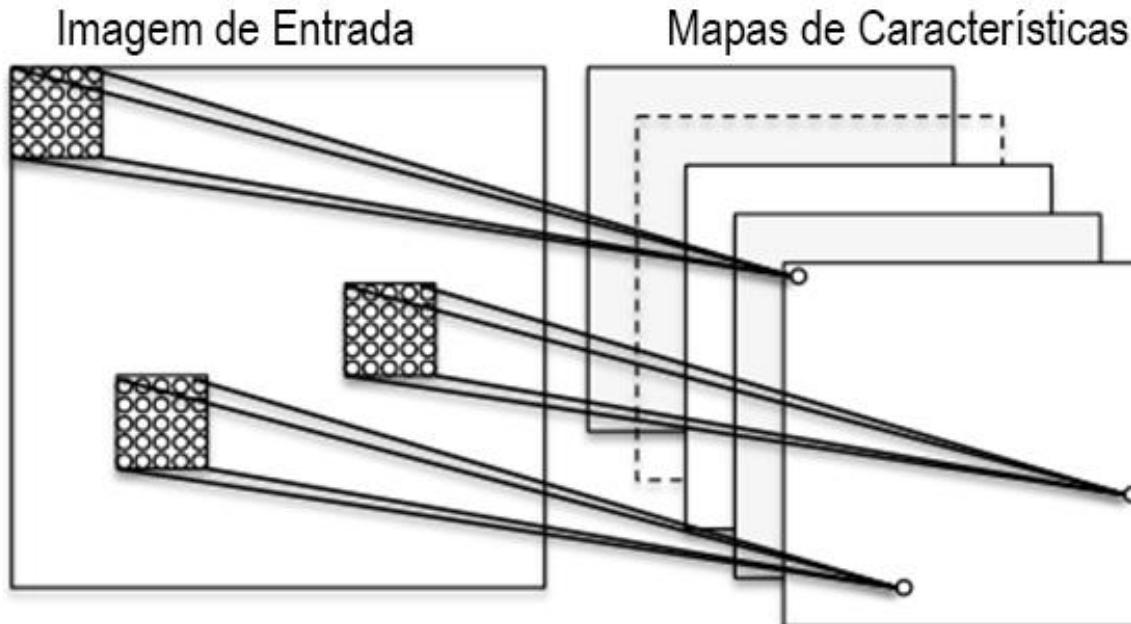
Filtros



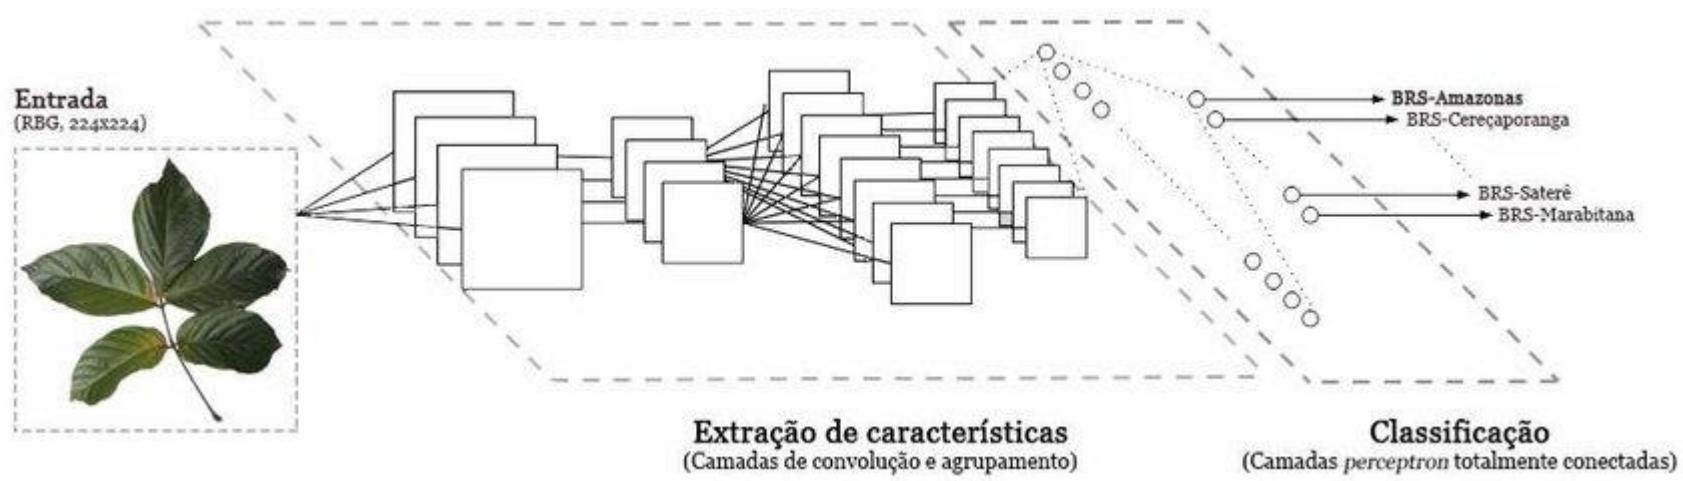
Mapas de Características (Feature Maps)

# Convolução

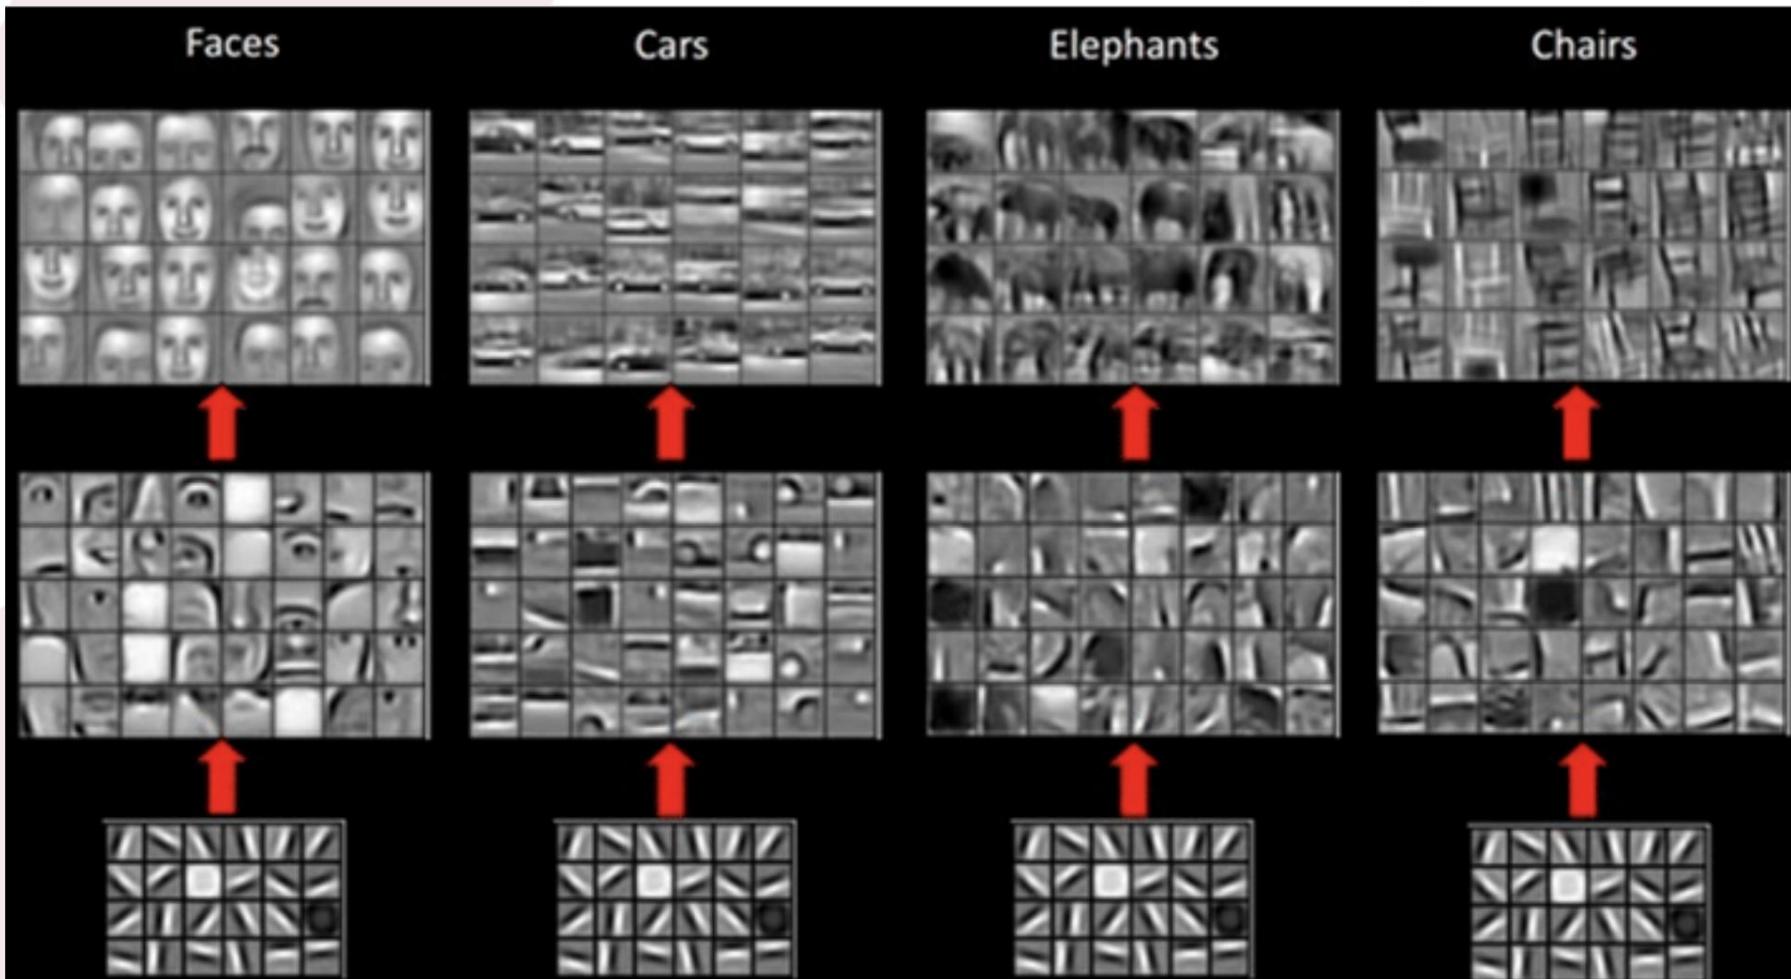
- O tamanho do **Mapa de Característica** é controlado por três parâmetros: **Profundidade (Depth)**, **Passo (Stride)** e **Preenchimento (Padding)**.



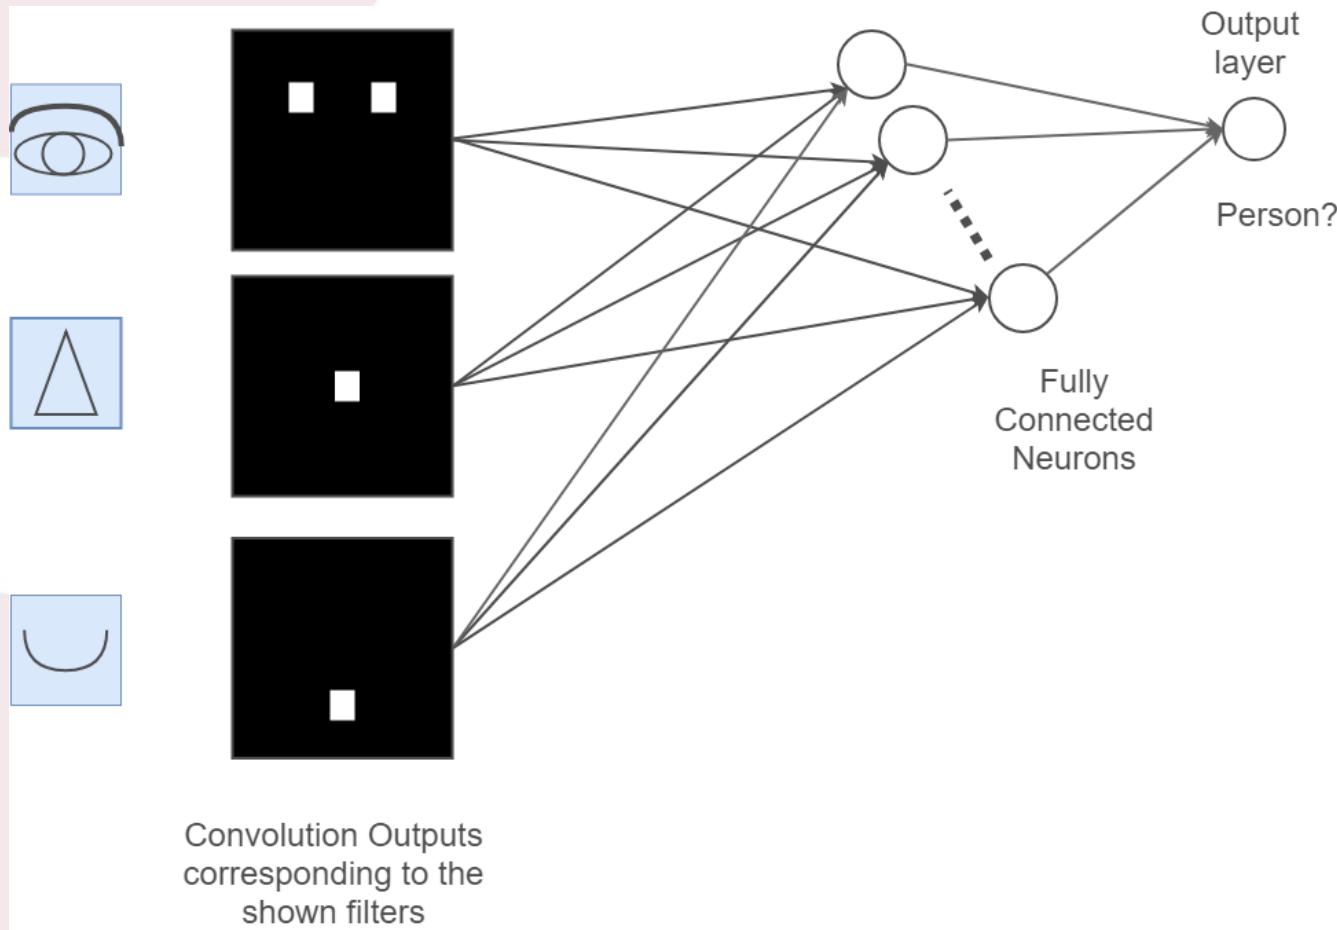
# Arquitetura



# Mapas de características gerados

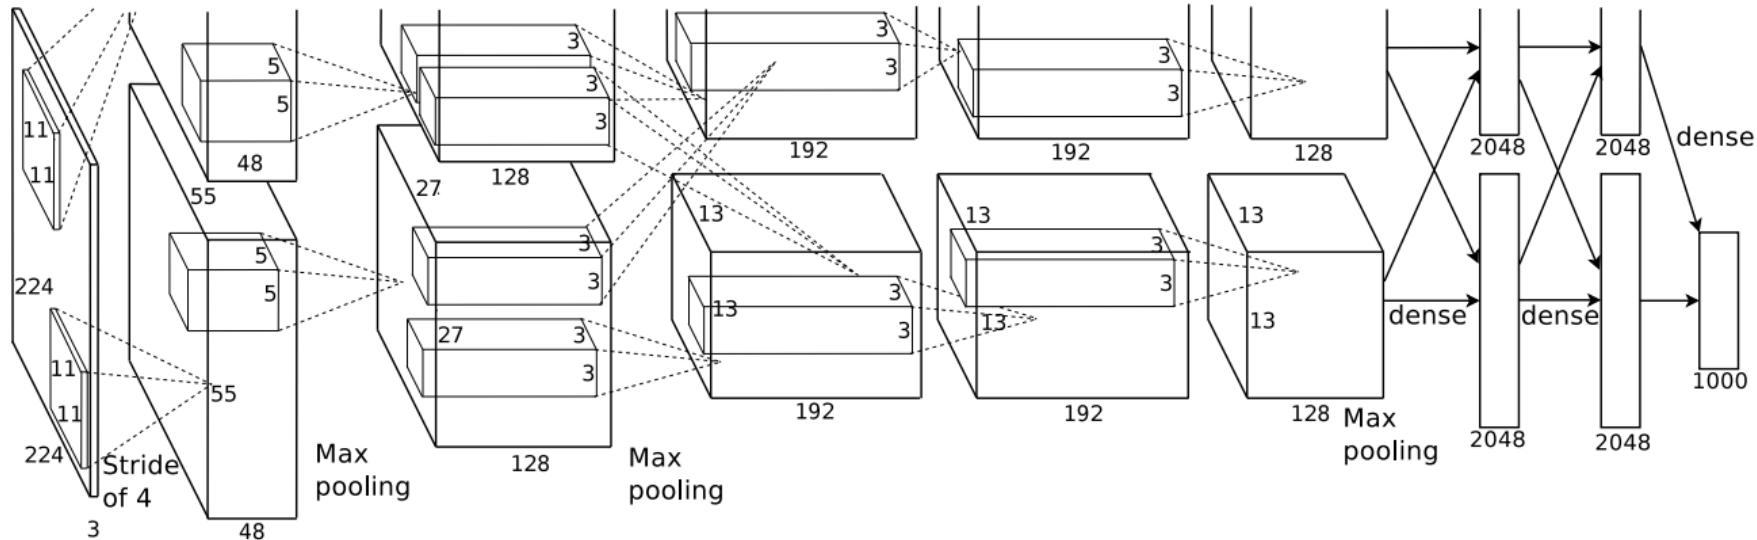


# Convolução



- AlexNet (2012);
- ZFNet (2013);
- VGGNet (2014);
- GoogleNet/Inception (2015);
- ResNet(2015).

# AlexNet (2012)

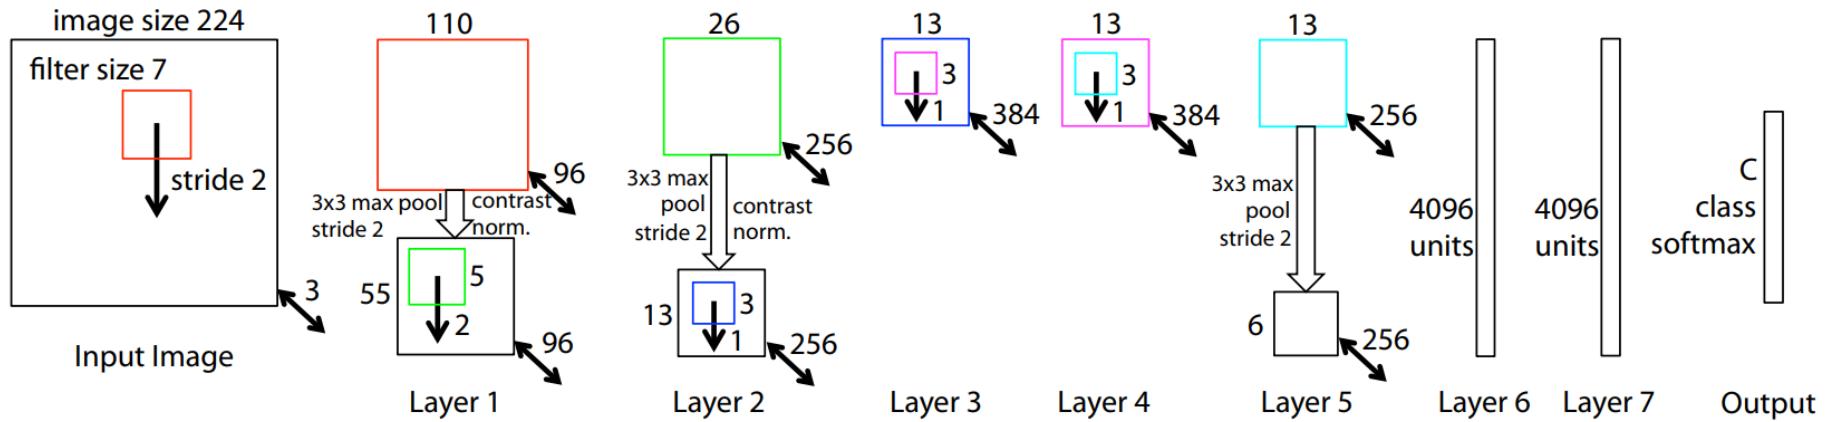


Arquitetura da CNN conhecida por **AlexNet**. Uma GPU executa a parte superior da imagem, enquanto que uma outra executa a parte inferior.

# AlexNet (2012)

- Treinada em **duas GTX 580 (1,5 GB ram)** com os dados da ImageNet por **5/6 dias**, contendo mais de **15 milhões de imagens rotuladas** em mais de **22 mil categorias**;
- Uso da técnica de **Data Augmentation**;
- Primeira CNN a conseguir um bom resultado na ImageNet.

# ZFNet (2013)

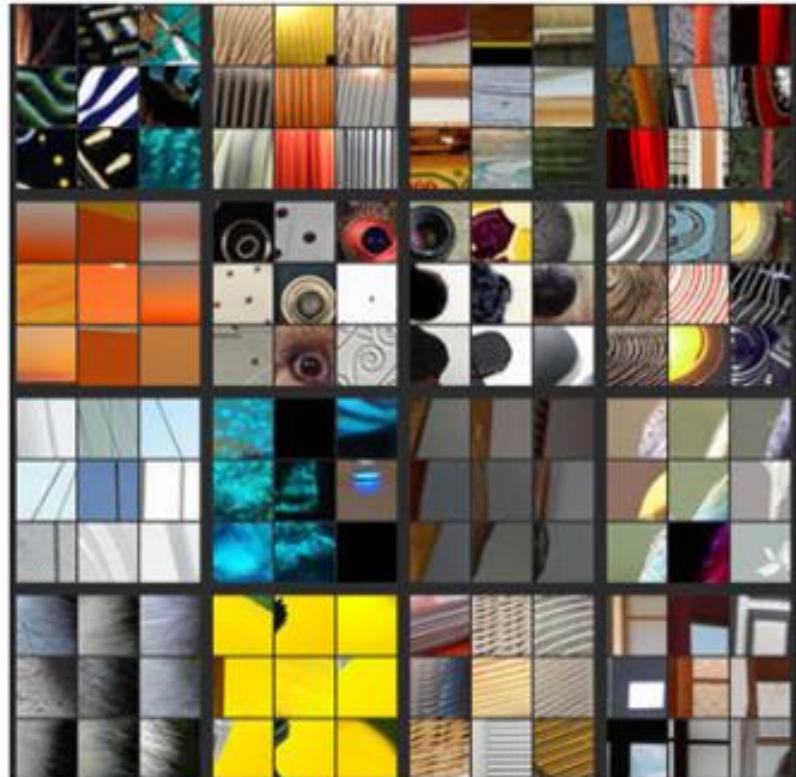
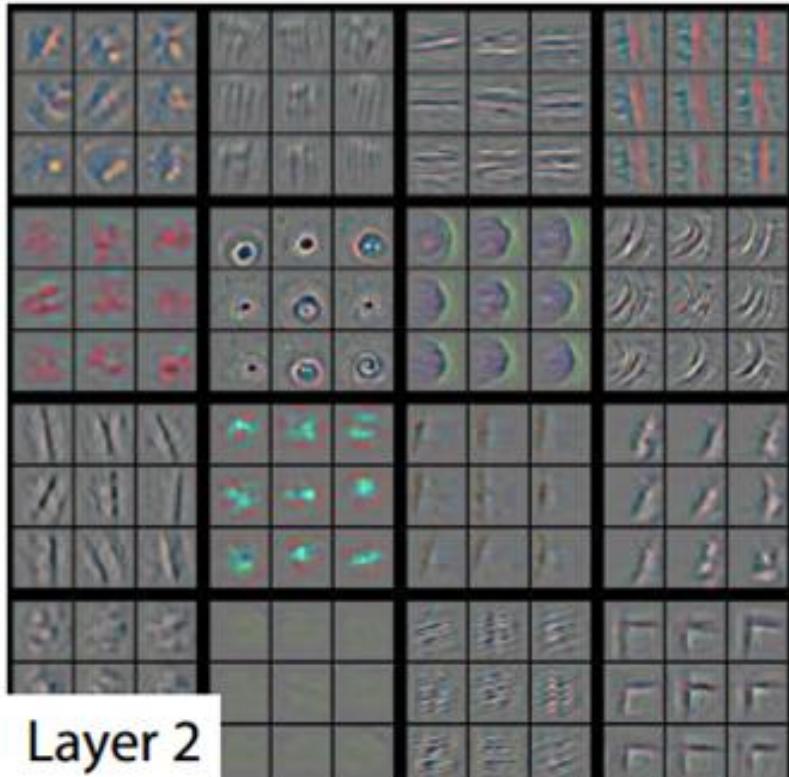


Arquitetura **ZFNet** bastante semelhante a AlexNet utilizando filtros 7x7 e um valor de *stride* menor na primeira camada com o objetivo de **reter mais informações da imagem de entrada**.

# ZFNet (2013)

- Treinada em uma **GTX 580 (1,5 GB ram)** por **12 dias** com 1.3 milhões de imagens;
- No mesmo trabalho foi desenvolvido uma técnica de visualização dos filtros chamado de **Deconvolutional Network (DeConvNet)**.

# ZFNet (2013)



Representação de 16 filtros diferentes para as imagens do lado direito.

# VGGNet (2014)

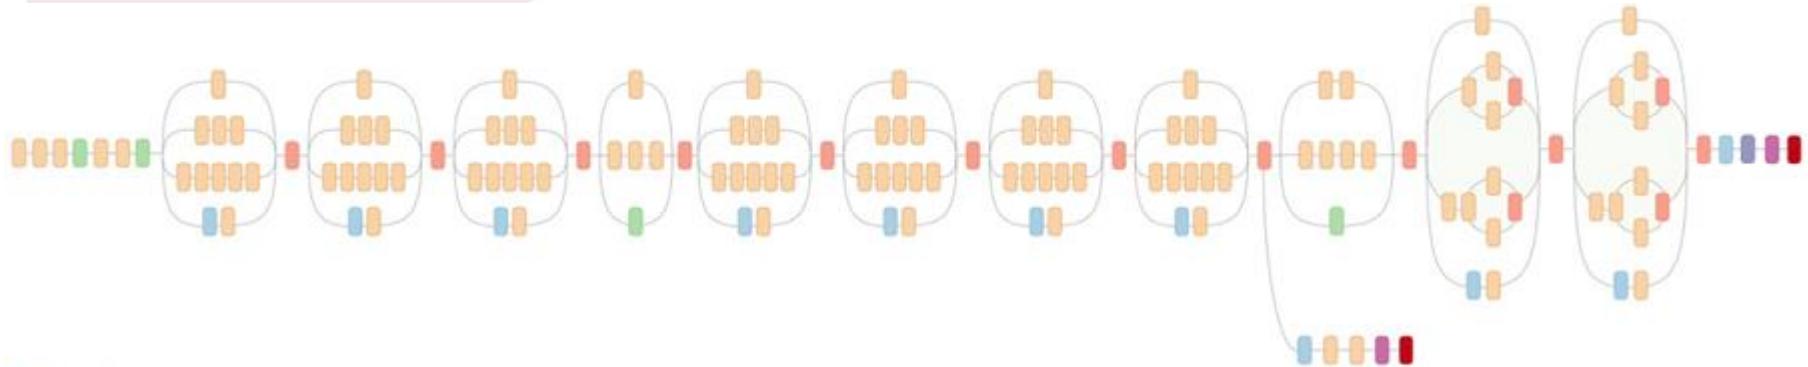
ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input ( $224 \times 224$ RGB image)					
conv3-64	conv3-64 <b>LRN</b>	conv3-64 <b>conv3-64</b>	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 <b>conv3-128</b>	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 <b>conv1-256</b>	conv3-256 conv3-256 <b>conv3-256</b>	conv3-256 conv3-256 conv3-256 <b>conv3-256</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Arquitetura VGG com 6 configurações diferentes.

# VGGNet (2014)

- Treinada em duas **Nvidia Titan Black (6GB ram)** por **2/3 semanas**;
- Aplicada para **classificação e localização**;
- Rede bastante profunda, mas simples em termos de tamanho de filtros.

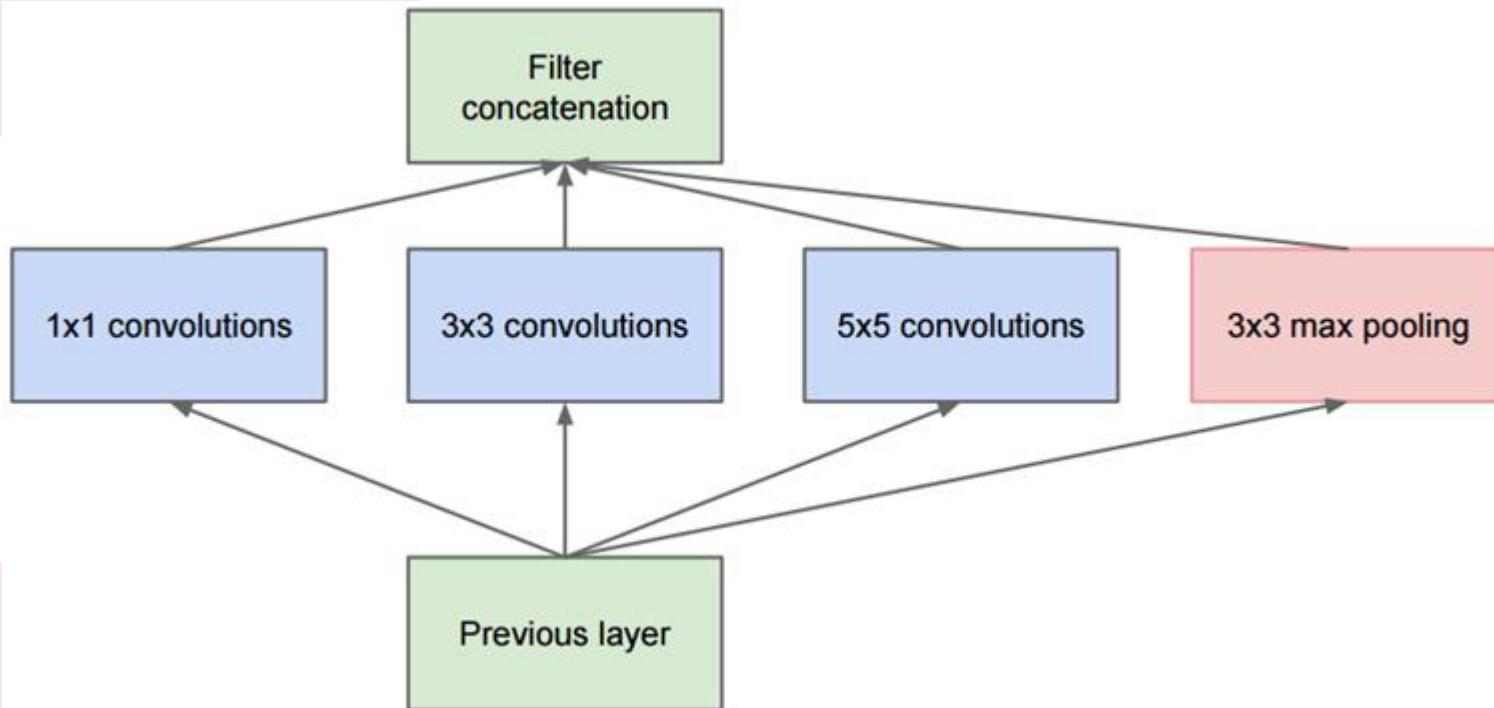
# GoogleNet/Inception (2015)



- Convolution
- AvgPool
- MaxPool
- Concat
- Dropout
- Fully connected
- Softmax

Arquitetura **GoogleNet** e seus modulos **Inceptions**.

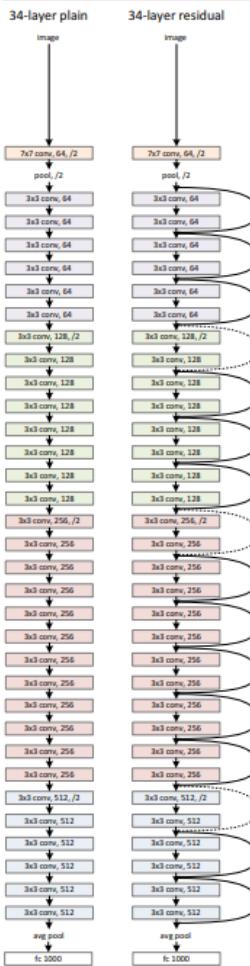
# GoogleNet/Inception (2015)



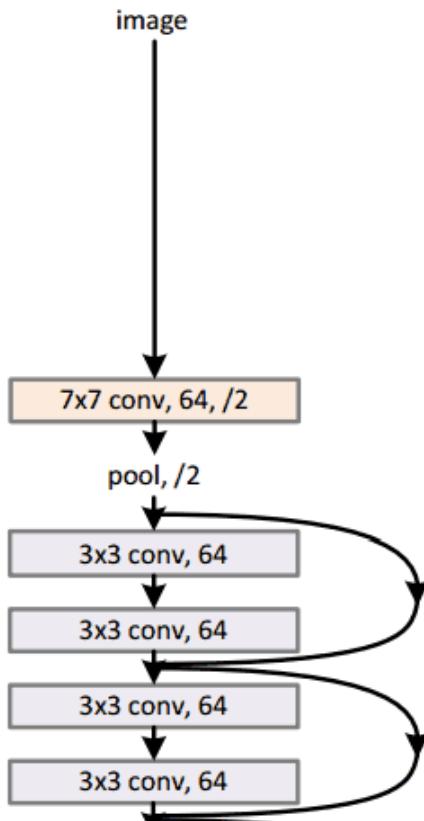
# GoogleNet/Inception (2015)

- Treinada com “algumas GPU de ponta” em **paralelo**;
- Utiliza 9 módulos Inception por toda a rede atingindo mais de **100 camadas**;
- Uma das primeiras redes a propor uma **arquitetura não sequencial**.

# ResNet (2015)



34-layer residual



Arquitetura **Microsoft ResNet** com 152 camadas atingiu bons resultados nos problemas de **classificação, detecção e localização**.

# ResNet (2015)

- Treinada em **8 GPUs** por 2/3 semanas;
- Testaram com **1202 camadas**, mas **não conseguiram bons resultados**;

# Aplicações

<https://lukeoakdenrayner.wordpress.com/2019/09/19/ai-competitions-dont-produce-useful-models/>

<http://scs.ryerson.ca/~aharley/vis/>

<https://paperswithcode.com/sota/image-classification-on-imagenet>

# Referências

- <http://scs.ryerson.ca/~aharley/vis/>
- <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>
- <https://towardsdatascience.com/light-on-math-machine-learning-intuitive-guide-to-convolution-neural-networks-e3f054dd5daa>
- <https://medium.com/datadriveninvestor/five-powerful-cnn-architectures-b939c9ddd57b>
- <https://adeshpande3.github.io/adeshpande3.github.io/The-9-Deep-Learning-Papers-You-Need-To-Know-About.html>

Pós-graduação em Ciência da Computação  
Centro de Informática  
Universidade Federal de Pernambuco

# **Redes Convolucionais Aplicadas em Visão Computacional**

Marcos José Canêjo Estevão de Azevêdo

[mjcea@cin.ufpe.br](mailto:mjcea@cin.ufpe.br)