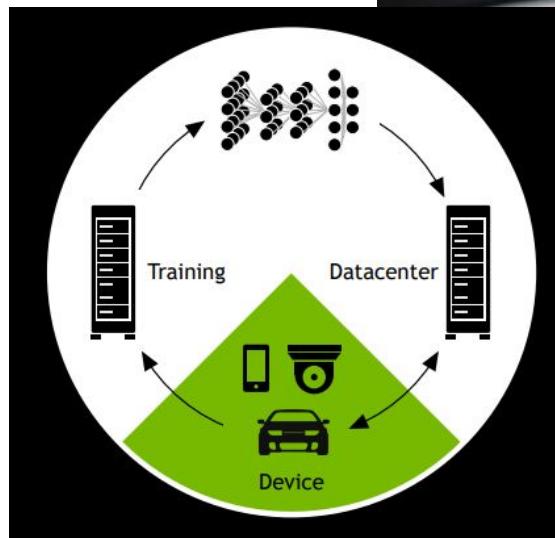


Universidade Federal do Paraná (UFPR)
Bacharelado em Informática Biomédica

AI / ML / Deep Learning



David Menotti

www.inf.ufpr.br/menotti/cic171-182

Objetivos

- Inteligência Artificial
 - Consciência
- Aprendizado de Máquinas
- *Deep Learning - Breakthroughs*
 - Histórico e eventos

Inteligência Artificial

- Questões filosóficas:
 - Uma máquina pode realmente pensar como um humano?
 - Uma máquina pode ser um humano?
- 1637 - **René Descartes** - “*Je pense, donc je suis!*”
 - ***Discours de la méthode: Pour bien conduire sa raison, et chercher la vérité dans les sciences***

“Se houvesse máquinas que tivessem uma semelhança com nossos corpos e imitassem nossas ações o mais próximo possível para todos os propósitos práticos, nós ainda deveríamos ter dois meios muito certos de reconhecer que eles não eram homens de verdade.”


- Máquina não poderia “falar” ou “juntar sinais”

Inteligência Artificial

- 1950 - O teste de Turing / “*The Imitation Game*” (1950)
 - “ Se um juiz não pode diferenciar entre um humano e uma máquina (interface texto), a máquina pode enganar o juiz a pensar que ele é o humano? ”
 - Previsão em 50 anos - Computadores com 1GB de RAM
 - 70% de certeza / 5 minutos de prova
 - Alan Turing (Pai da Ciência da Computação)
 - Nasceu em 23.06.1912 / Morreu 07.02.1954
 - *The Imitation Game* (2014)

Inteligência Artificial

- Computadores / Máquinas tem consciência?



Consciência - Ficção

An epic drama
of adventure
and exploration

- 1968 – 2001: A Space Odyssey (Stanley Kubrick)

- Hal
- Monolito

MGM PRESENTS A STANLEY KUBRICK PRODUCTION

2001
a space
odyssey.

STARRING
KEIR DULLEA • GARY LOCKWOOD

SCREENPLAY BY
STANLEY KUBRICK AND ARTHUR C. CLARKE

PRODUCED AND DIRECTED BY
STANLEY KUBRICK

SUPER PANAVISION™
in METACOLOR



Consciência - Ficção

- 1982 – Blade Runner (Harrison Ford)





Consciência - Ficção

- 2017 – Blade Runner (Ryan Gosling / Harrison Ford)



Consciência - Ficção

- 1984 – *The Terminator* (Arnold Schwarzenegger)
 - Sara Connor
- 1991 – *The Terminator 2* (Arnold Schwarzenegger)
 - Skynet - 29 de Agosto de 1997
- ???



Consciência - Ficção

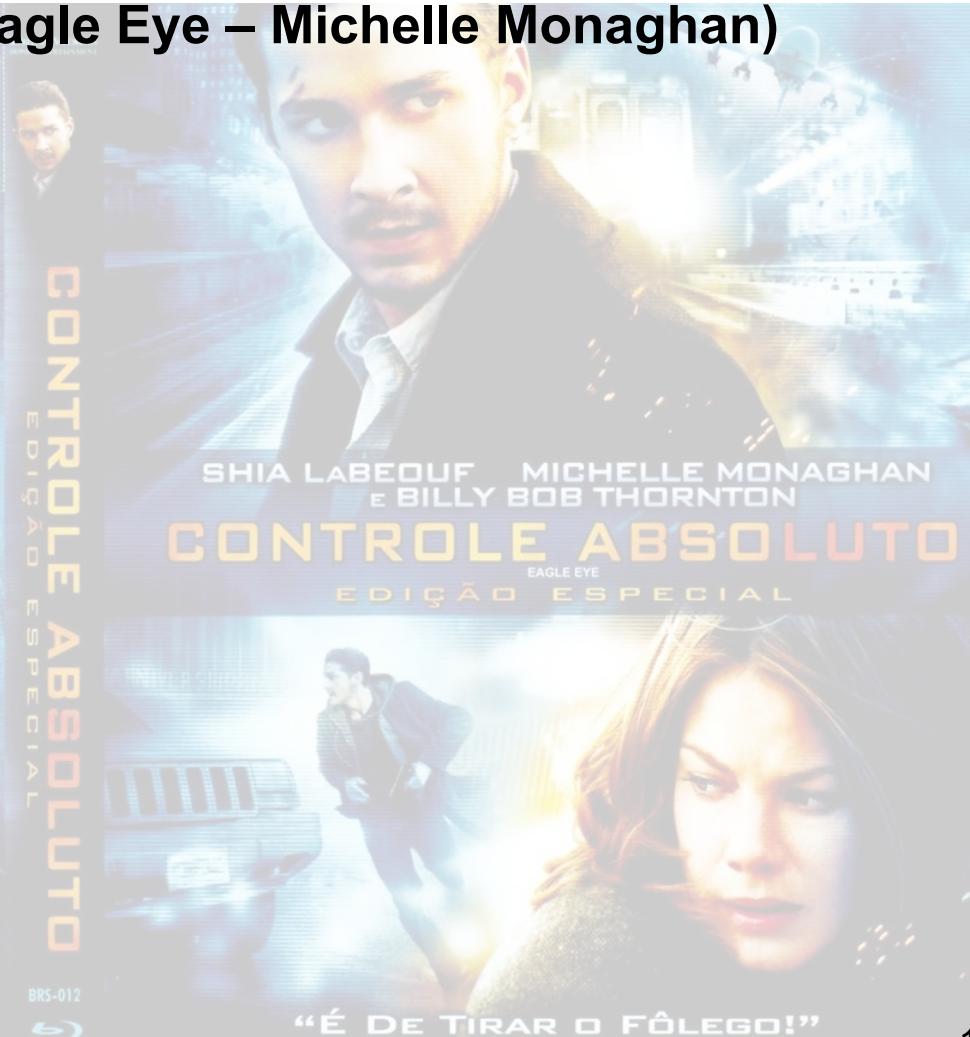
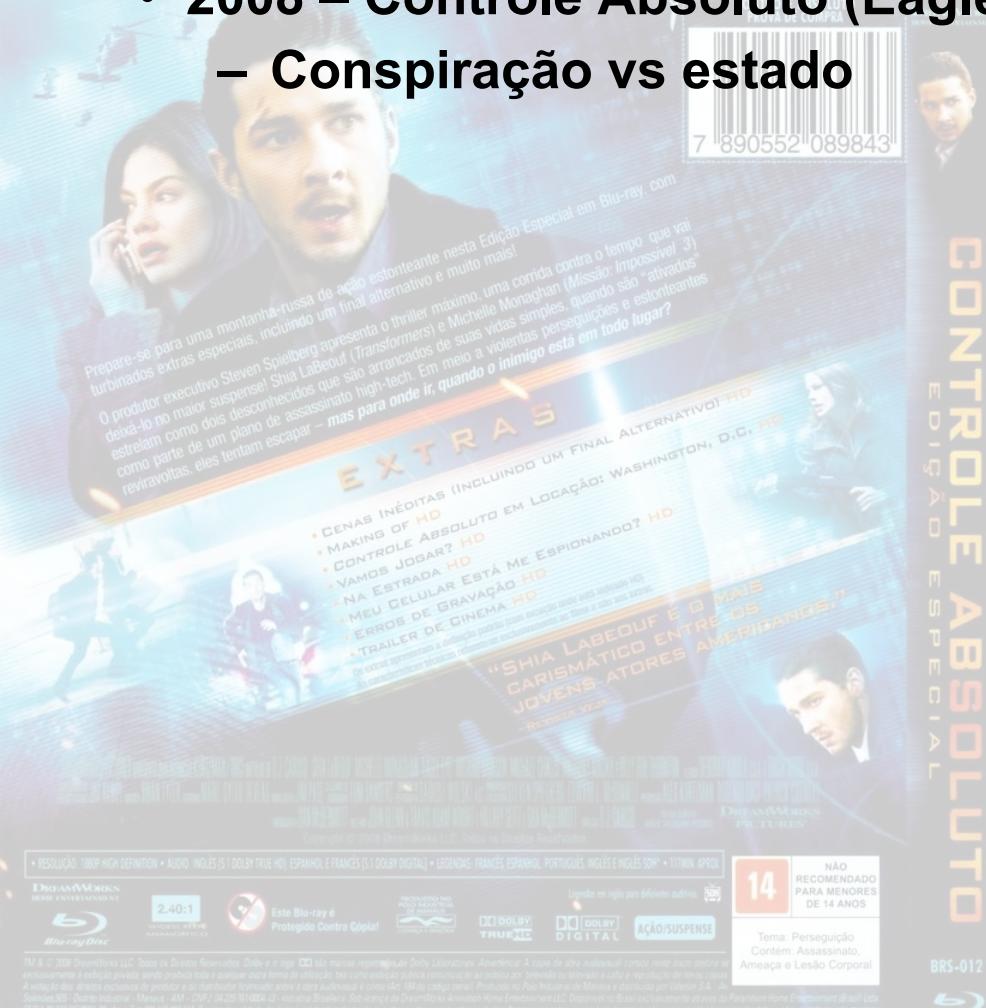
- 1999 – *Bicentennial Man* (Robin Williams)
 - Quis se tornar uma máquina

Consciência - Ficção

- 2004 – Eu, Robô (*I, Robot* – Will Smith)
 - Do bem e do mal

Consciência - Ficção

- 2008 – Controle Absoluto (Eagle Eye – Michelle Monaghan)
 - Conspiração vs estado



JUDE LAW

HALEY JOEL OSMENT

Consciência - Ficção

- 2011 - *Artificial Intelligence* (Jude Law)
 - Não sabe que é máquina

A STEVEN SPIELBERG FILM



ARTIFICIAL INTELLIGENCE

Consciência - Ficção

- 2014 - *Transcendence* (Johnny Depp)
 - Consciência transplantada

Consciência - Ficção

- 2016 *Ex-Machina*
 - Engana o ser humano



Consciência - Realidade

- As máquinas têm consciência?



Aprendizado de Máquinas

- Mas as máquinas já “aprendem” !!!



grille	mushroom	cherry	Madagascar cat
convertible	agaric	dalmatian	squirrel monkey
grille	mushroom	grape	spider monkey
pickup	jelly fungus	elderberry	titi
beach wagon	gill fungus	ffordshire bullterrier	indri
fire engine	dead-man's-fingers	currant	howler monkey

Inteligência Artificial

- **1995 Veículos Autônomos (*Self-driven Car*)**

- 1980s Vario Mercedes-Benz
- 1995 S-Class W140 modificado - Mercedes-Benz (1986 → 2021)
 - trecho : Munique até Copenhagen (1678 Km) - **quase autônomo**
 - *Computer Vision & Microprocessadores*
 - 180 km/h, Ultrapassagem, Interpretava Placas de Trânsito
- 2009 Waymo (Google)
 - Hoje (2017) empresa independente
 - Sensores & Câmeras
- 2020 Uber & Waymo - U\$ 100k
 - 19.03.2018 - Vítima Fatal (Arizona)

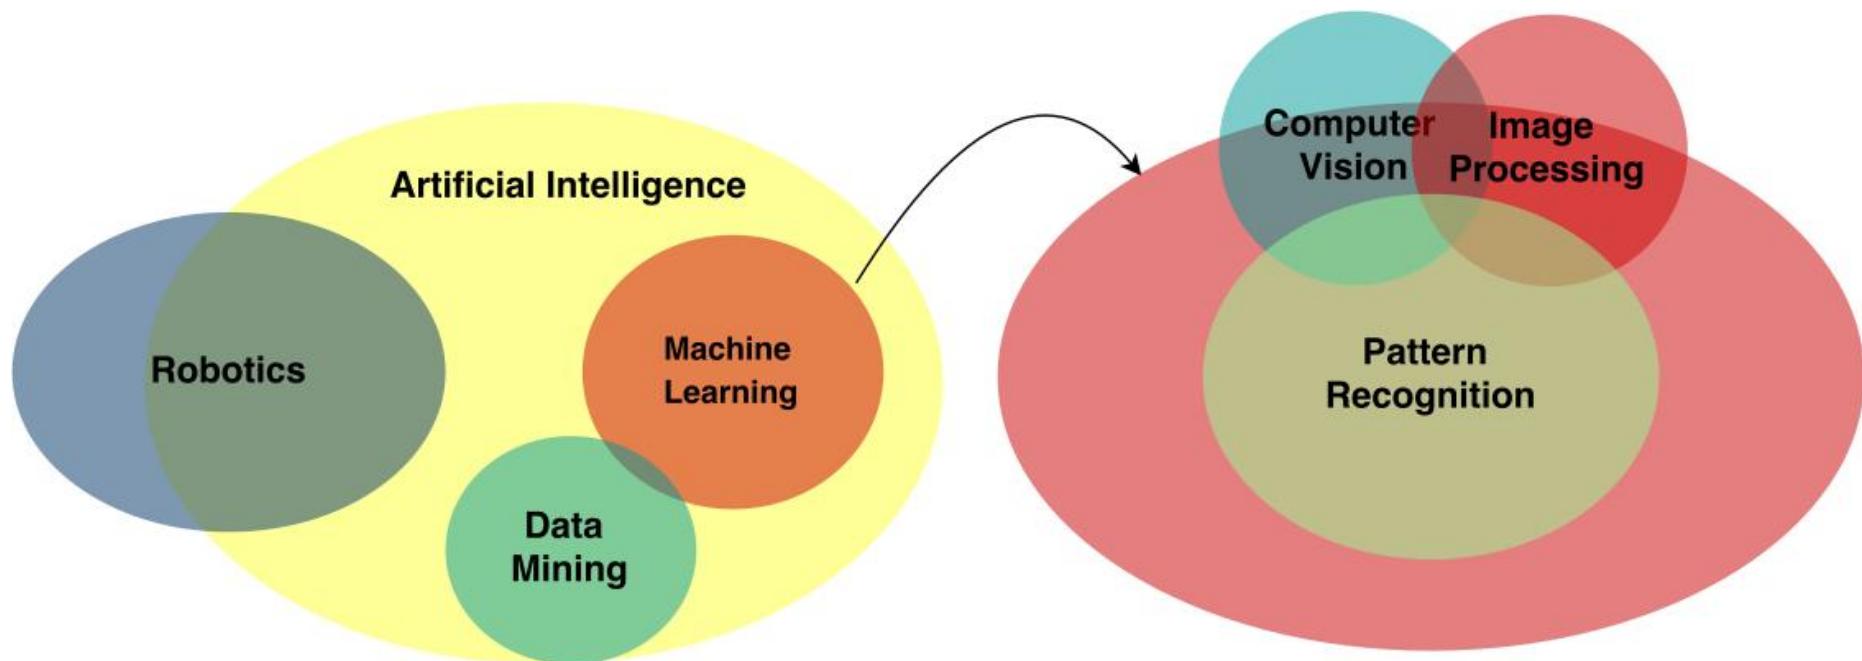


Inteligência Artificial

- **1996/1997 Garry Kasparov vs *Deep Blue***
 - 1996 Kasparov vence *Deep Blue* (IBM) por 4-2
 - Ainda usando modelos baseados em regras (IA clássica)
 - 1997 *Deep Blue* 2 - 3 (empates) - 1 Kasparov
 - Inteligência Artificial ilusória
 - "Ele está jogando contra os fantasmas dos grandes mestres do passado"
 - » IBM alimentou o sistema com dados de milhares de jogos anteriores
 - » *Deep Blue* não “aprendia”, usava a experiência

Inteligência Artificial

- Uma visão da “hierarquia” da área



Aprendizado de Máquinas

- **Redes Neuronais Artificiais**
 - 1951 “SNARC”
(Stochastic Neural Analog Reinforcement Computer)
 - Feita de tubos e válvulas
 - Ajudar um rato virtual a resolver um problema
 - 1960-1980 Pesquisa em Inteligência Artificial
 - Clássica (*ruled based*)
 - 1988 Estística
 - IBM’s TJ Watson Research Center
 - *A statistical approach to language translation*

Como Aprende?


- Ser Humano:
 - Bons exemplos
 - Erros - correção
- Uma “máquina”?
 - Bons exemplos
 - Erros - correção

Humano vs “Máquina”

- Cérebro vs Modelo Neuronal (2000/2010)

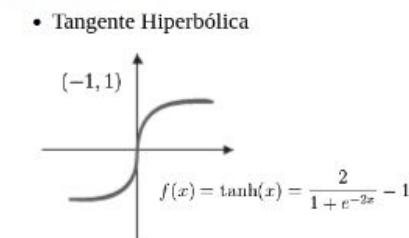
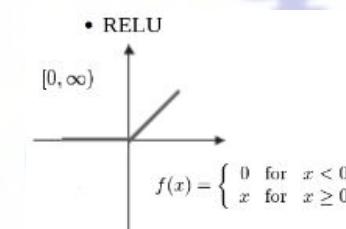
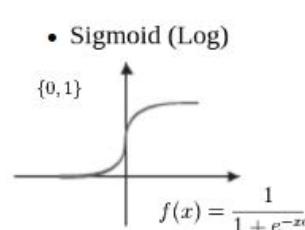
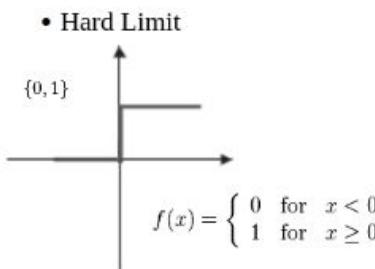

Parâmetro	Cérebro	Computador
Material	Orgânico	Metal e Plástico
Velocidade	Milisegundos	Nanosegundos
Tipo de Processamento	Paralelo	Sequêncial
Armazenamento	Adaptativo	Estático
Controle de Processos	Distribuído	Centralizado
Número de Elementos Processados	10^{11} a 10^{14}	10^5 a 10^6
Ligações entre Elementos Processados	10.000	< 10

Rede Neuronal



O Perceptron

- 1957 - Criação
 - Entradas
 - Pesos e *Bias*
 - Soma Ponderada
 - Função de Ativação
 - ***Classificador Binário
- Funções de ativação

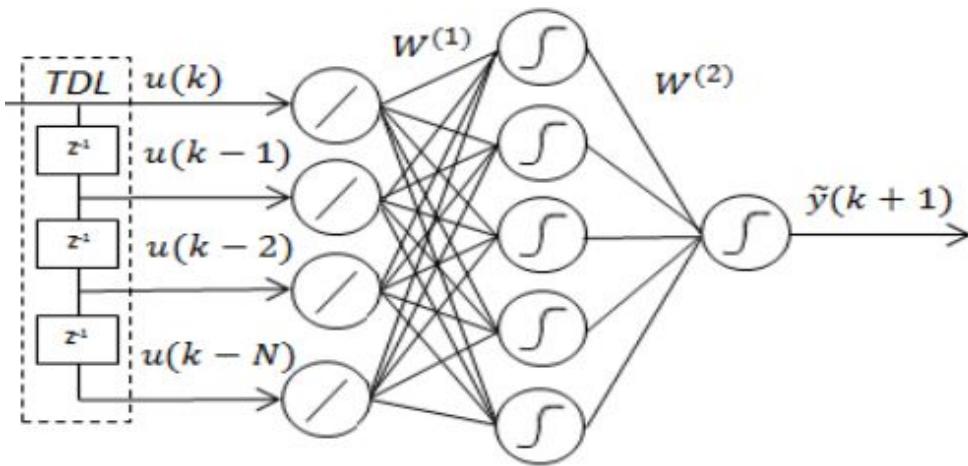


- Rosenblatt, Frank (1957), The Perceptron--a perceiving and recognizing automaton. Report 85-460-1, Cornell Aeronautical Laboratory.

O Perceptron

- 1957 - Algoritmo de aprendizado???
 - 1969 - Caiu em descrédito
 - Evolução da IA Clássica
 - 1986 - O Back-propagation*
 - 1989 - Teorema Universal de Aprixomação
 - Uma camada, qualquer função contínua
 - 1991 - Multiple-Layer Perceptron
 - Função de ativação
-
- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (8 October 1986). "Learning representations by back-propagating errors". *Nature*. **323** (6088): 533–536.

Propagação (*forward*)




$$z_j = f\left(\sum_i w_{ji}^{(1)} x_i\right),$$

$$\tilde{y}(k+1) = g\left(\sum_j w_j^{(2)} z_j\right),$$

- onde z_j é o valor de saída do neurônio
 - $\tilde{y}(k+1)$ é o valor do último neurônio
 - $w^{(1)}$ e $w^{(2)}$ são os pesos da cam. escondida e saída
 - $f()$ and $g()$ são as saídas das funções de ativação da camada escondida e saída
- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (8 October 1986). "Learning representations by back-propagating errors". *Nature*. **323** (6088): 533–536.

Propagação (*forward*)

- *Multi-Layer Perceptron (MLP)*



Back-propagation

- Cálculo de gradientes locais:

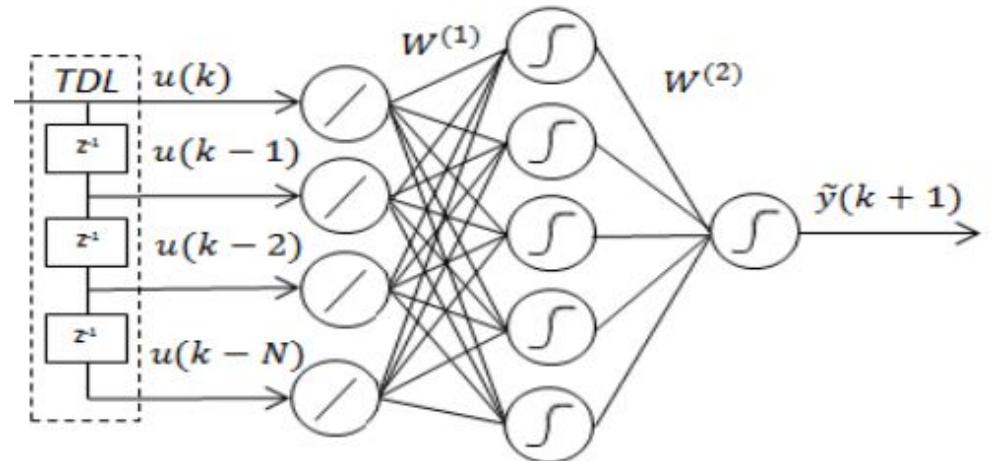
$$\delta^{OUT} = t(k+1) - \tilde{y}(k+1),$$

➡ $\delta_j^{HID} = f'(z_j)w_j^{(2)}\delta^{OUT}.$

- Cálculo das derivadas

$$\frac{\partial E(k)}{\partial w_j^{(2)}} = \delta^{OUT} z_j,$$

$$\frac{\partial E(k)}{\partial w_{ji}^{(1)}} = \delta_j^{IN} x_i.$$



- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (8 October 1986). "Learning representations by back-propagating errors". *Nature*. **323** (6088): 533–536.

Back-propagation

- Cálculo de gradientes locais:

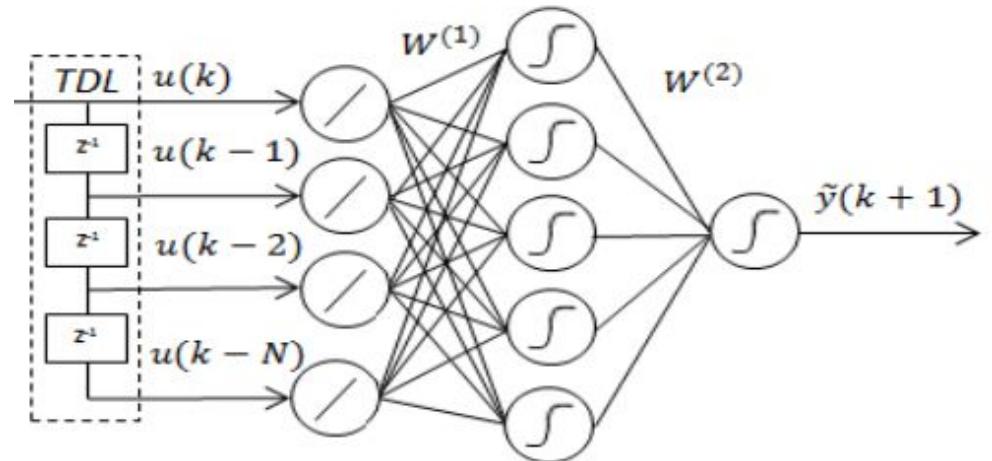
$$\delta^{OUT} = t(k+1) - \tilde{y}(k+1),$$

➡ $\delta_j^{HID} = f'(z_j)w_j^{(2)}\delta^{OUT}.$

- Cálculo das derivadas

$$\frac{\partial E(k)}{\partial w_j^{(2)}} = \delta^{OUT} z_j,$$

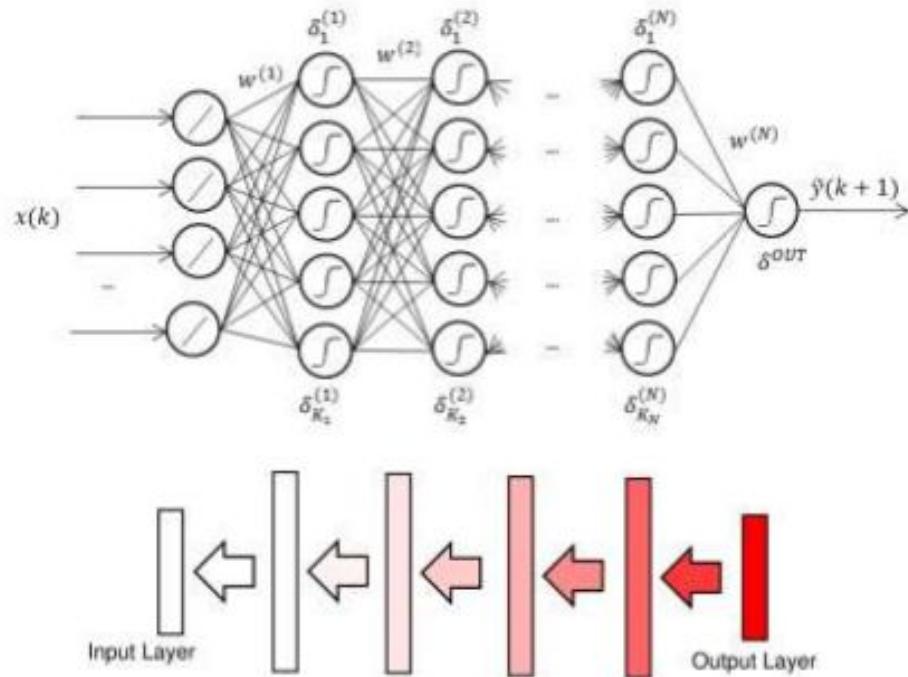
$$\frac{\partial E(k)}{\partial w_{ji}^{(1)}} = \delta_j^{IN} x_i.$$



- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (8 October 1986). "Learning representations by back-propagating errors". *Nature*. **323** (6088): 533–536.


Efeito ruim do *vanish gradient*

- Multiple-layer Perceptron



$$\delta_j^{(m)} = f_j^{(m-1)} \sum_i w_{ij}^{(m)} \delta_i^{(m+1)},$$

$$\frac{\partial E(k)}{\partial w_{ji}^{(m)}} = \delta_j^{(m)} z_i^{(m-1)},$$



$\frac{\partial E(k)}{\partial w_{ji}^{(m)}} \rightarrow 0 \text{ for } m \rightarrow 1$

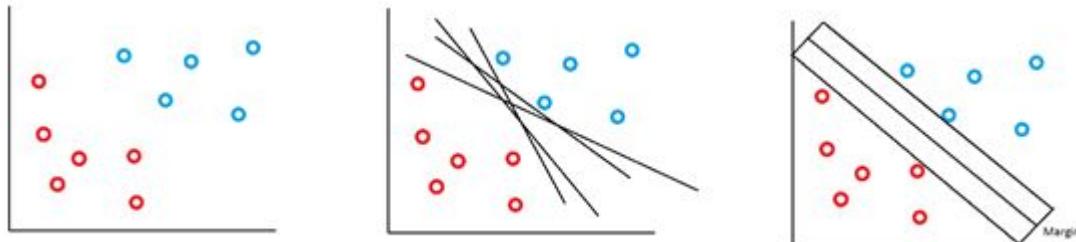
Multiple-layer Perceptron

- Cenário em 1995-2000s
 - Limitadas a 2/3 camadas (*vanish gradient*)
 - Processo de aprendizado caro computacionalmente
 - A escolha da arquitetura é dependente da complexidade do problema
 - Ajuste de parâmetros (*learning rate & momentum*)

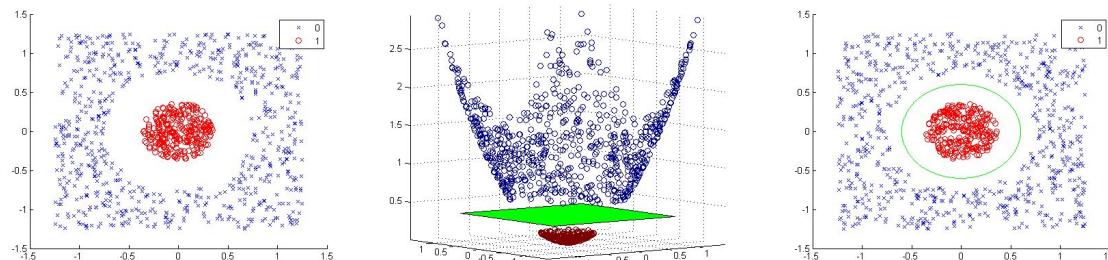
Support Vector Machines

- 1995

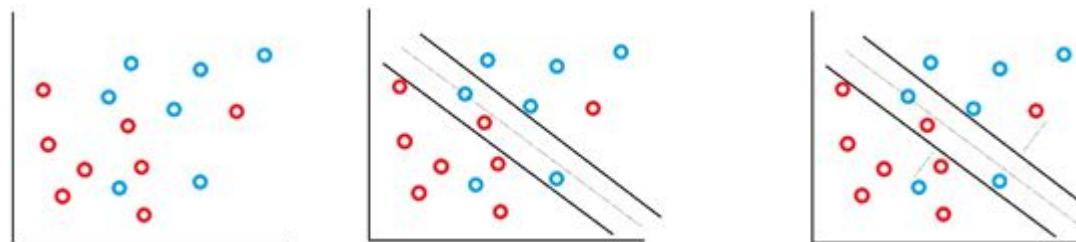
Linear (1963)



Kernel Trick (1992)



Soft Margin (1995)



- Cortes, C. & Vapnik, V. N. Support-vector Networks. Machine Learning 20 (3), 1995



Referências

- James O'Malley **The 10 most important breakthroughs in Artificial Intelligence**
<https://www.techradar.com/news/the-10-most-important-breakthroughs-in-artificial-intelligence>
- Seth Weidman **The 4 Deep Learning Breakthroughs You Should Know About**
<https://towardsdatascience.com/the-5-deep-learning-breakthroughs-you-should-know-about-df27674ccdf2>
- Artem Chernodub, Geroge Pashchenko, **Details of Lazy Deep Learning for Images Recognition in ZZ Photo app**, Kharkob AI Club, 2015
- Alex Oagana **A Short History of Mercedes-Benz Autonomous Driving Technology**
<https://www.autoevolution.com/news/a-short-history-of-mercedes-benz-autonomous-driving-technology-68148.html>


Deep Learning

- ***Deep Learning*** é como sexo na adolescência.
 - Todo mundo fala sobre
 - Ninguém realmente sabe como fazer
 - Todo mundo pensa que todo mundo está fazendo
 - Então, todo mundo diz que está fazendo



Adaptado de [Dan Ariely](#) (Big Data)

Deep Learning

- Fatores que influenciam
 - Desenvolvimento de Algoritmos
 - Hardware capaz de processar grandes massas de dados (GPU)
 - Disponibilidade de dados anotados
 - Imagens no Facebook
 - Voz e Texto no Google




Tradicional x Deep Learning



Convolução

- Chave em *Deep Learning*
 - Pesos compartilhados



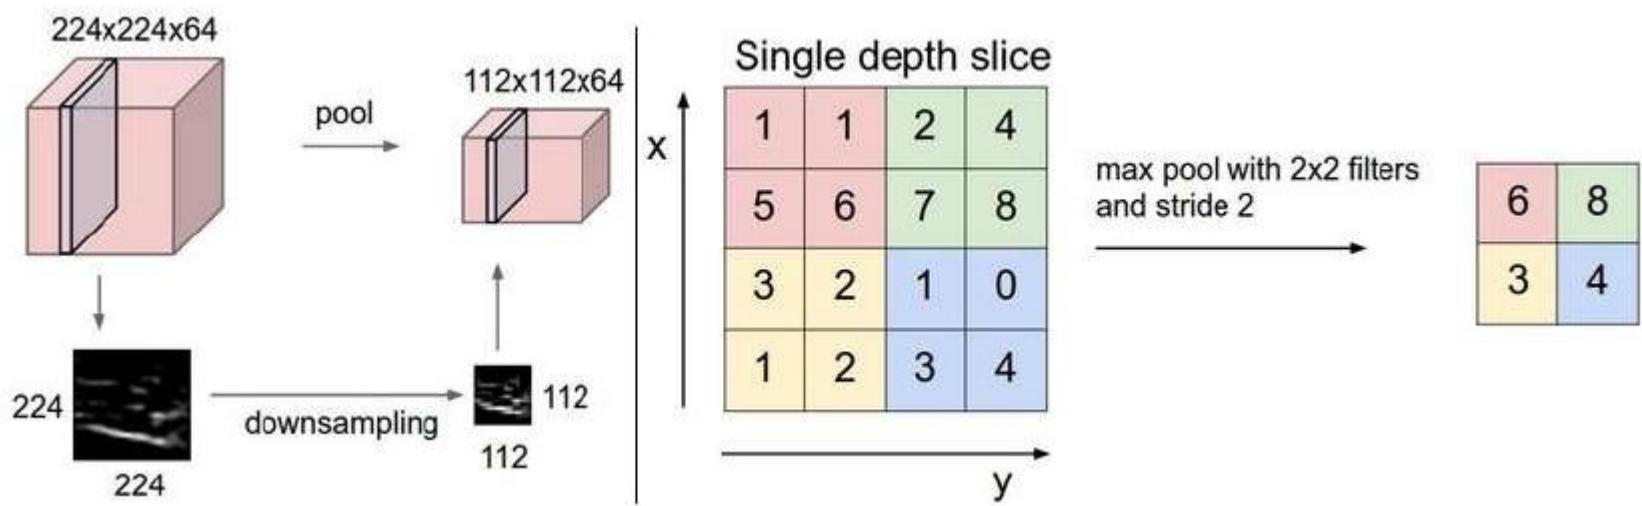
1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

Image

Convolved Feature

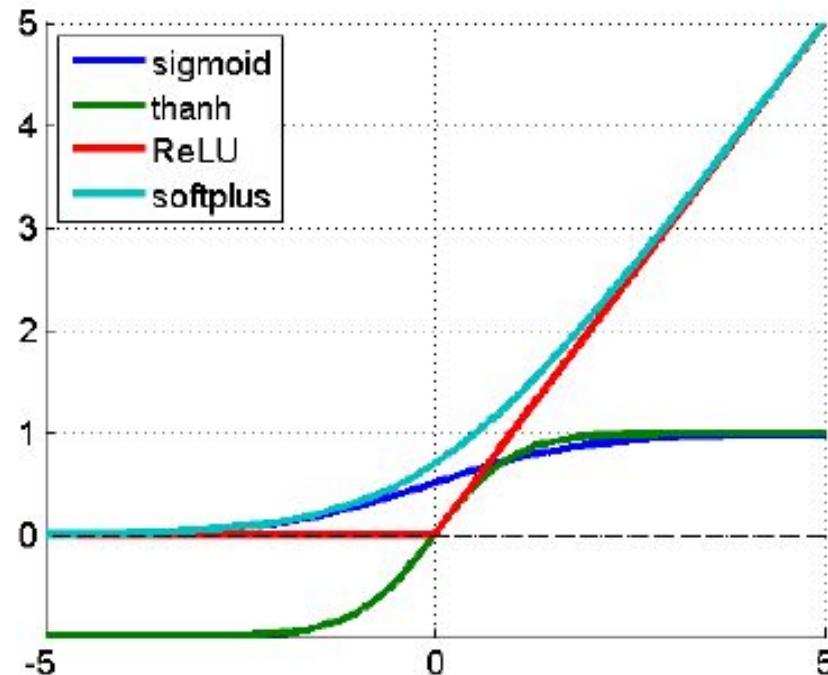
Pooling

- Largamente utilizado
 - Reduz **dim.** representação



Funções de ativação

- ReLU elimina o problema do
vanish gradient




$$f(x) = \max(0, x)$$

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

- Yoshua **Bengio**, Ian Goodfellow and Aaron Courville. Deep Learning. MIT Press.
<http://www-labs.iro.umontreal.ca/~bengioy/DLbook> (citado por 3467 jul/2018)

LeNet (Lecun)

- 1998 - 1a. CNN implementada com sucesso (Bell Labs)
 - Reconhecimento de Dígitos Manuscritos
 - Imagem de entrada de **32x32 pixels**
 - MNIST Dataset (10 classes [0-9])
 - #60k *train* / #10k *test*
 - 0,95% / \sim 345 k conexões \sim 60k parâmetros



- Y. **LeCun**, L. Bottou, Y. **Bengio** & Patrick Hater, Gradient Based Learning Applied to Document Recognition, Proc. of IEEE, 1998

LeNet (Lecun)

- Arquitetura
 - Pesos & Bias (340.908 / 60.000)

- - C1: conv: 6@5x5 => 122.304 ($6 \times (5 \times 5 + 1) = 156$) => 6@28x28
 - S2: pool: 2x2 => 5.880 ($6 \times 2 = 12$) => 6@14x14
 - C3: conv: *@5x5 => 151.600 ($(6 \times 60 \times 5 \times 5) + 16 = 1.516$) => 16@10x10
 - S3: pool: 2x2 => 2.000 ($16 \times 2 = 32$) => 16@5x5
 - C5: fully: 16@5x5 => 48.120 ($16 \times 5 \times 5 + 1$) $\times 120$ => 120
 - F6: fully: 120x84 => 10.164 ($84 \times (120 + 1)$) => 84**
- => **60.000 total**
- Out: fully: 84x10

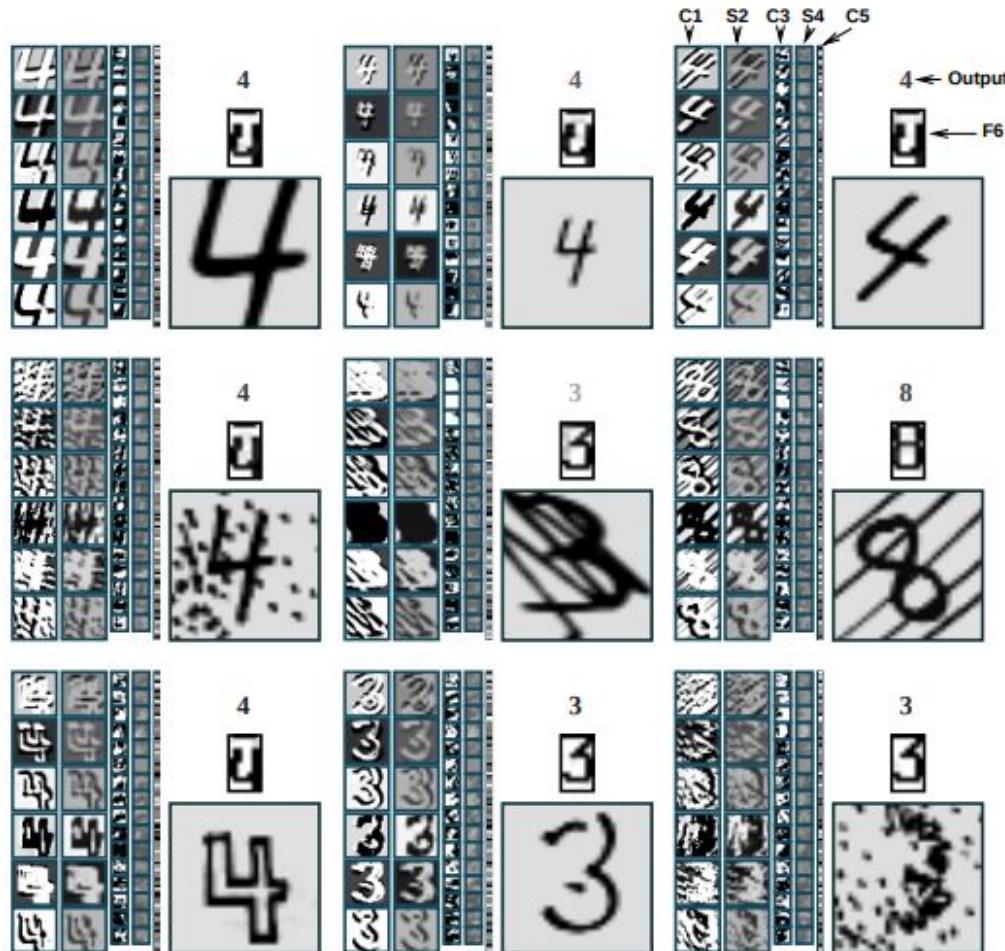
Camada C3

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	X			X	X	X			X	X	X	X		X	X	
1	X	X			X	X	X			X	X	X	X		X	
2	X	X	X			X	X	X		X		X	X	X		
3		X	X	X			X	X	X	X		X	X	X		
4			X	X	X			X	X	X	X	X	X		X	
5			X	X	X			X	X	X	X	X	X		X	

Camada F6

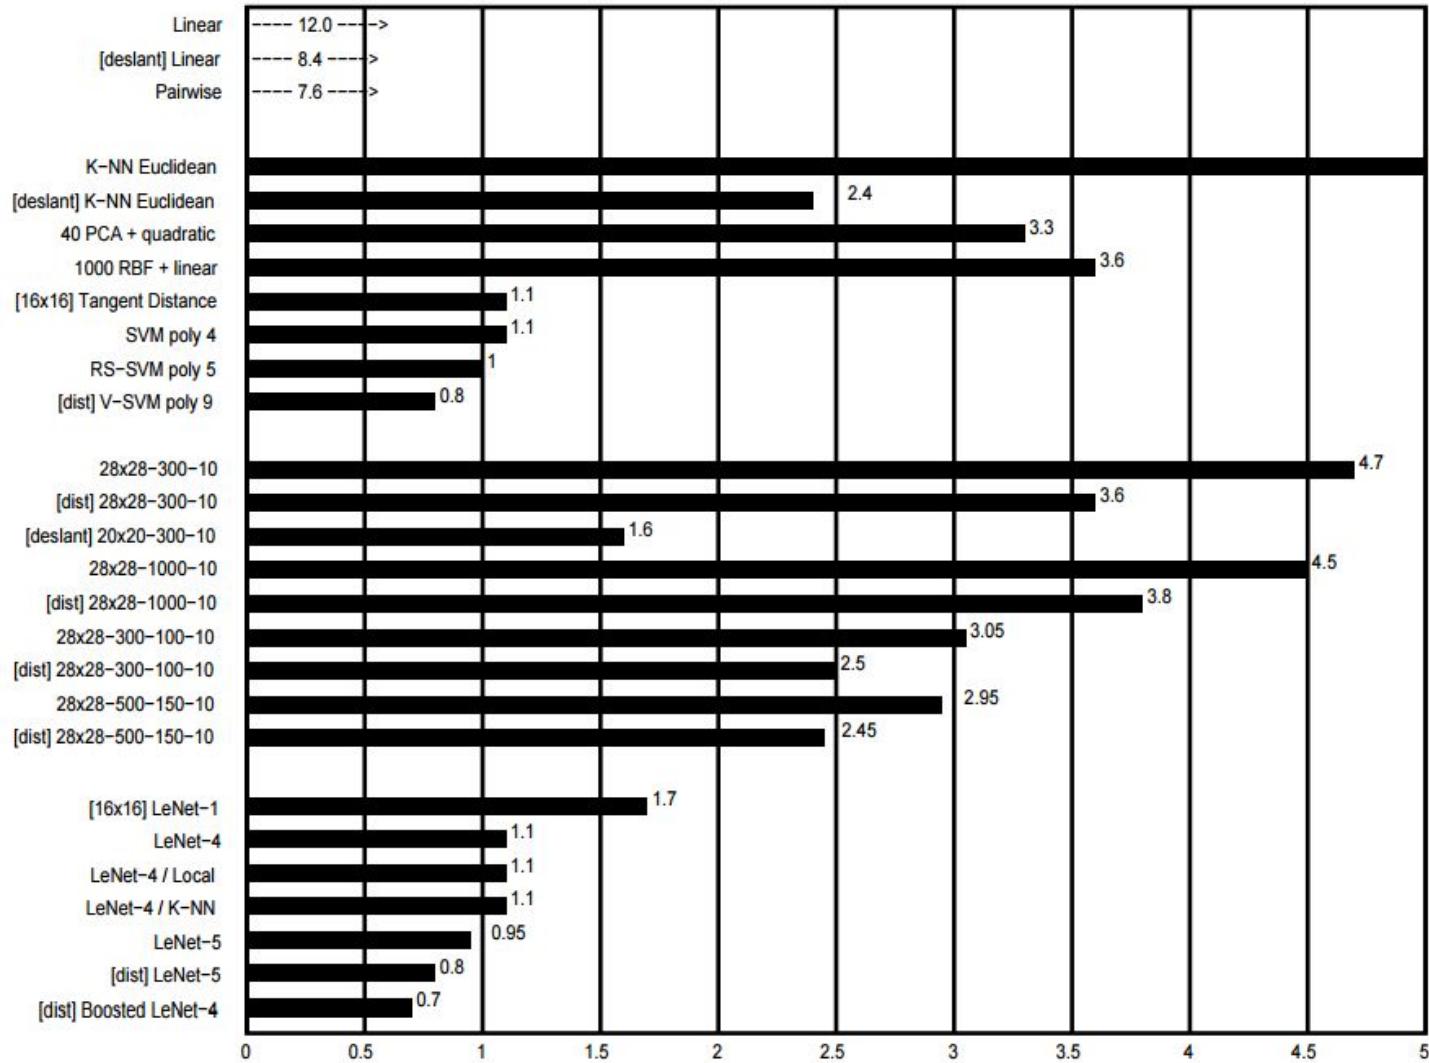


LeNet - Funcionamento

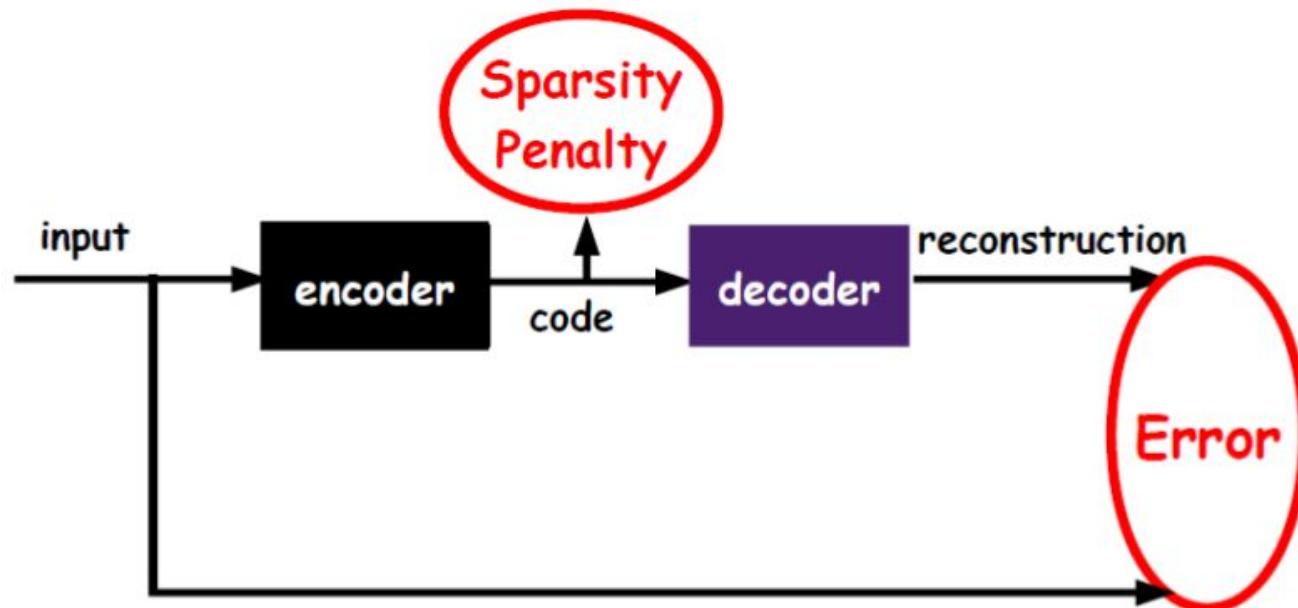


Robusto a ruídos, inclinação e forma

LeNet vs State of the Art



Sparse Autoencoders




- input: X code: $h = W^T X$

- loss: $L(X; W) = \|W h - X\|^2 + \lambda \sum_j |h_j|$

Eventos

- **2006 - Autoencoders**
 - Redução de Dimensional.
 - Uso de RBM empilhados como um deep auto-encoder
 - i. Treinar RBM usando imagens como saída e entrada



- G. E. Hinton & R. R. Salakhutdinov. *Reducing the Dimensionality of Data with Neural Networks*, Science 313 (2006), p. 504–507.

Eventos

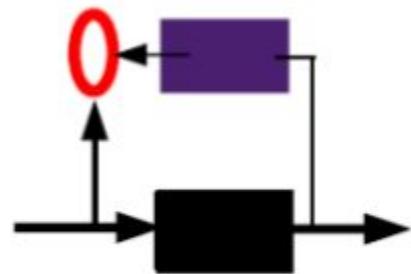
Olivetti face data, 25x25 pixel images reconstructed from 30 dimensions ($625 \rightarrow 30$)



- G. E. Hinton & R. R. Salakhutdinov. *Reducing the Dimensionality of Data with Neural Networks*, Science 313 (2006), p. 504–507.


Unsupervised Pre-training

- 1) Dado uma imagem (não rotulada), aprenda características



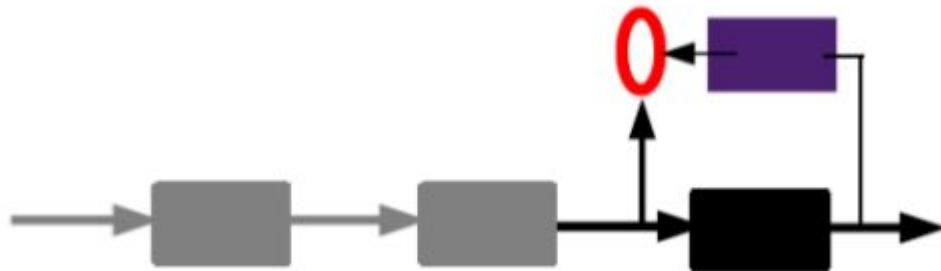
Unsupervised Pre-training

- 1) Dado uma imagem (não rotulada), aprenda características
- 2) Use o encoder para produzir novas features e treinar outra camada



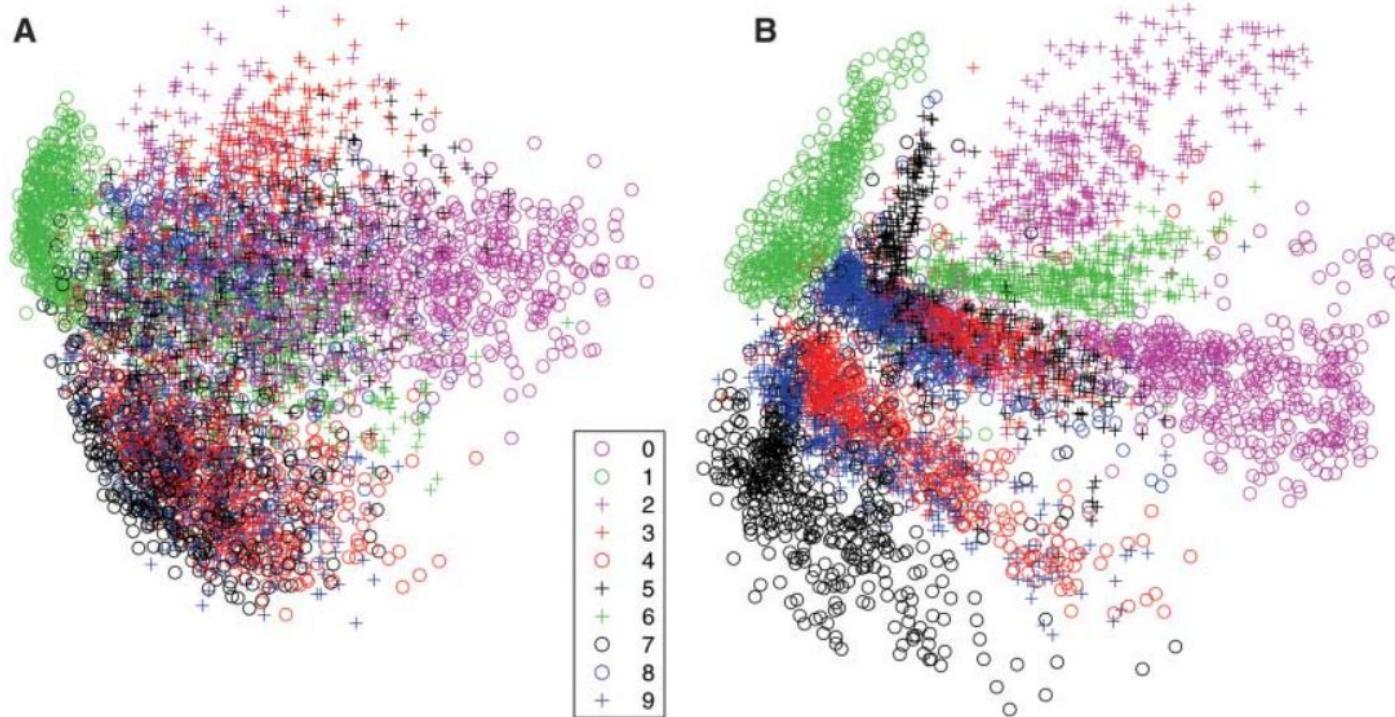
Unsupervised Pre-training

- 1) Dado uma imagem (não rotulada), aprenda características
- 2) Use o *encoder* para produzir novas *features* e treinar outra camada



Eventos

- 2006 - Autoencoders
 - PCA vs (784-1000-500-250-2) autoencoder * $28^2 = 784$




- G. E. Hinton & R. R. Salakhutdinov. *Reducing the Dimensionality of Data with Neural Networks*, Science 313 (2006), p. 504–507.


Eventos

- **2006 - Autoencoders**
 - 804'414 news da Reuters, redução para 2D
 - PCA **vs** 2000-500-250-125-2 autoencoder

PCA



Deep RBN



Eventos


- Dados não rotulados estão disponíveis
- Exemplos: Imagens da web
 - a. Baixar 10.000.000 imagens
 - b. Treinar uma DNN 9-camadas
 - c. Conceitos são formados pela DNN



- Q. V. Le, M. Ranzato, R. Monga, M. Devin, K. Chen, G. S. Corrado, J. Dean ^ ^
(citado por 1610 jul/2018) Using Large Scale Unsupervised Learning in ICML 2012

Eventos

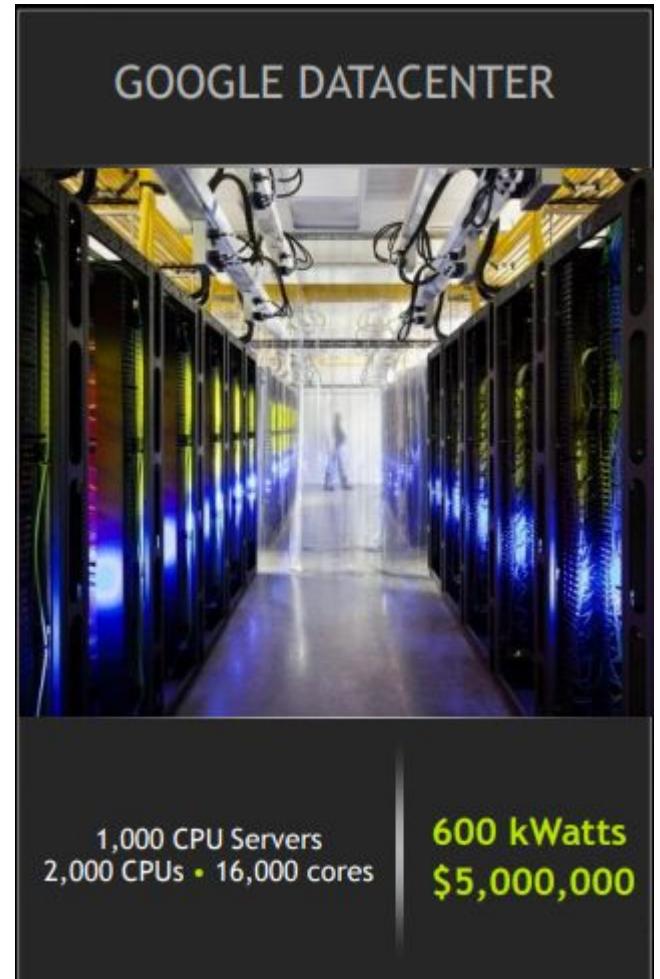
- Deep Auto-Encoder (Unsupervised) - ImageNet
 - 10M Images **200x200 pixels** / 20 Classes
 - Cluster (1k CPUs / 16k cores)




- Q. V. Le, M. Ranzato, R. Monga, M. Devin, K. Chen, G. S. Corrado, J. Dean ^ ^
(citado por 1610 jul/2018) **Learning Features using Large Scale Unsupervised Learning** in ICML 2012

Eventos

- **2010 - Google Brain**
 - 1,000 CPUs (16k cores)
 - 600 kWatts
 - U\$ 5.000.000
 - Prédio / Refrigeração
 - *Self-driving cars*
 - *Voice Recognition*



Eventos



NVIDIA CEO - Jensen Huang

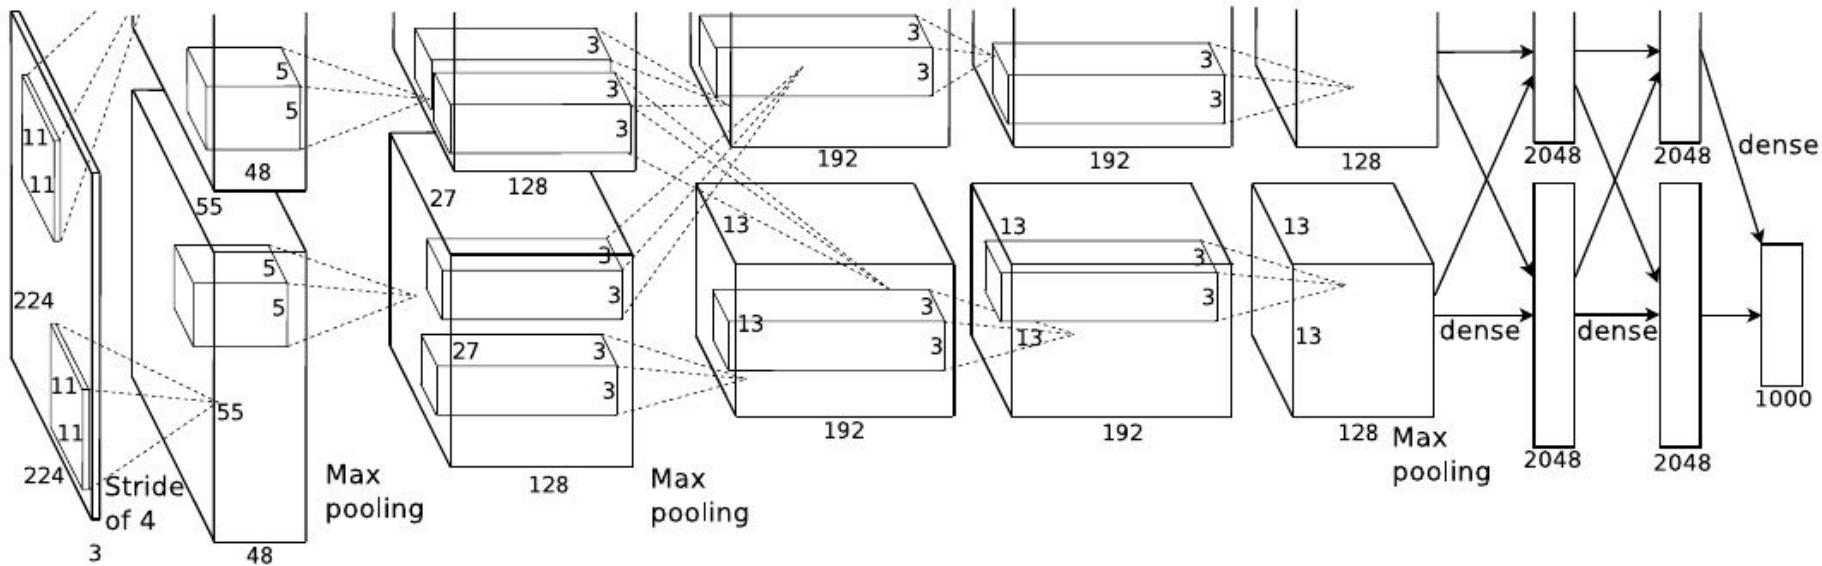


- 2013 - **NVIDIA**
 - GTC (2014)
 - 3 Servidor (12 GPUs)
 - 18.432 cores
 - 4 KWatts
 - U\$ 33.000
- GPUs 20-50x +CPUs
 - 2010?

- A. Coates, B. Huval, T. Wang, D. Wu, **A. Ng**, B. Catanzaro (421 citações - jul/2018)
Deep learning with COTS HPC systems - Int. Conf Machine Learning (ICML) 2013

Eventos


- **AlexNet (ImageNet) / Cuda-ConvNet**



- 60M parametrôs / 650K neurônios
- 3 GPUs - limitado tamanho modelo pela RAM das GPUs
- ImageNet (15M images / 22k classes) - erro caiu para 15%
- A. Krizhevsky, I. Sutskever, G.E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. NIPS, 2012. (+26 mil citações jul/2018)

AlexNet (ImageNet)

- 1 Test / 6 Train (*menor distância*)

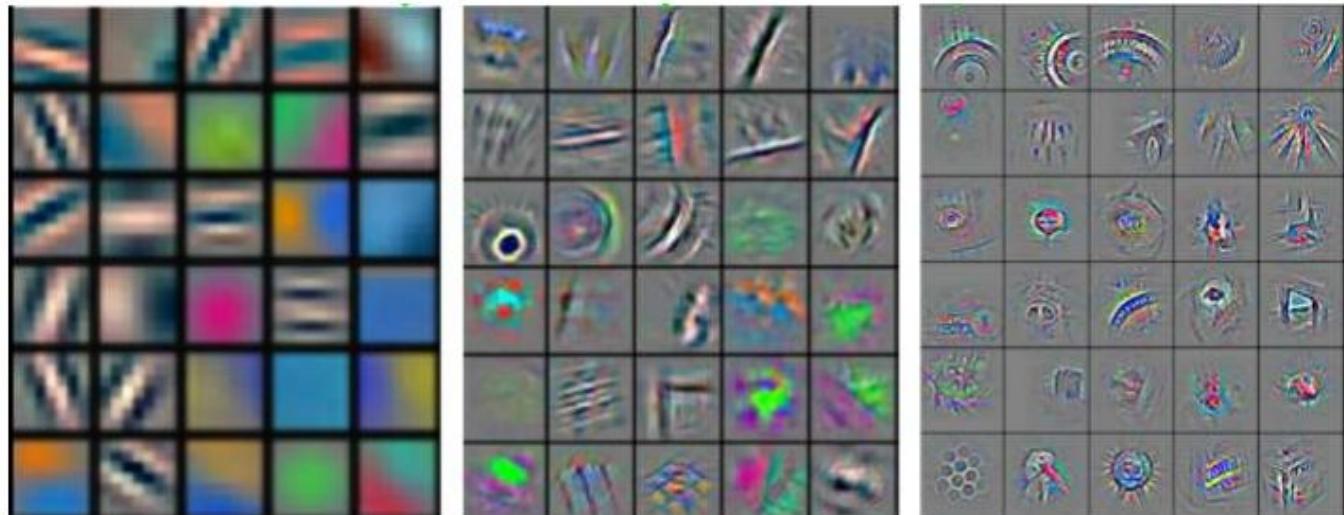



AlexNet (ImageNet)

- Classes *Top 5*




Hierarquia das Representações Treinadas



- Zeiler & Fergus. *Visualizing and Understanding Convolutional Networks*. European Conference on Computer Vision, 2014

ImageNet



“Deep Image: Scaling up Image Recognition”

- Baidu: 5.98%, Jan. 13, 2015

“Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification”

- Microsoft: 4.94%, Feb. 6, 2015

“Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariant Shift”

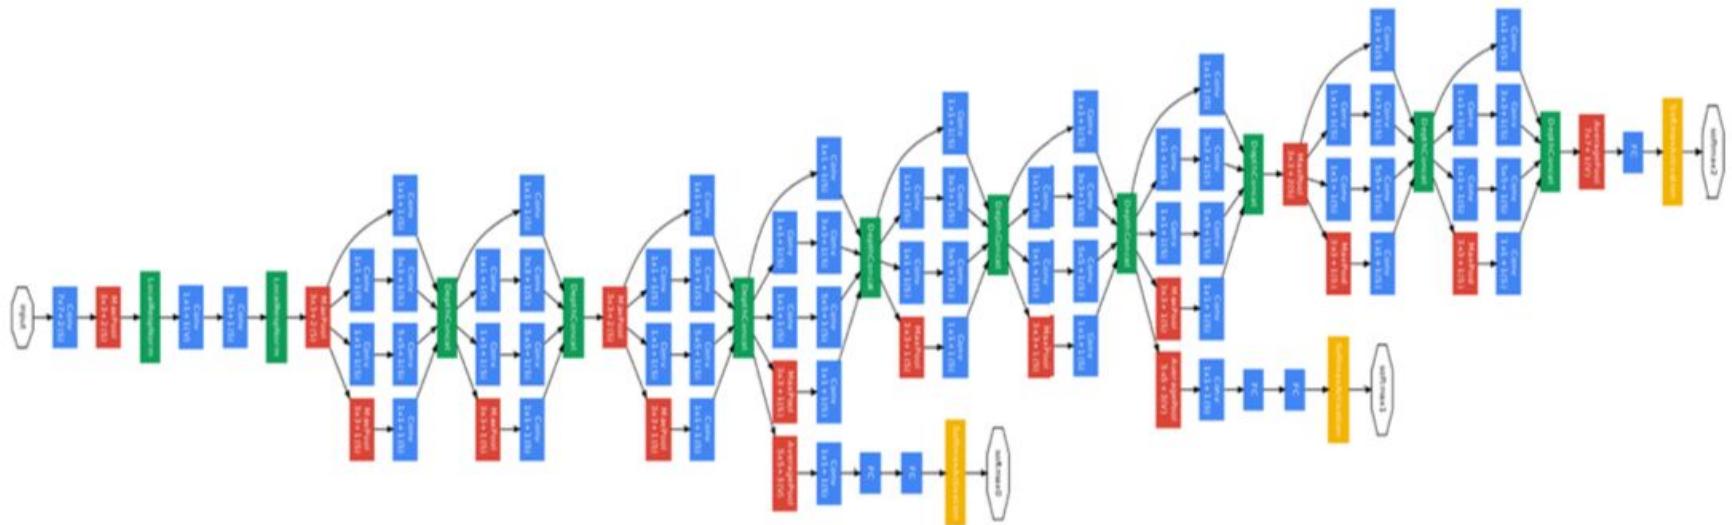
- Google: 4.82%, Feb. 11, 2015

- Larry Brown (Ph.D), Deep Learning with GPUs,
GEOINT 2015 - http://www.nvidia.com/content/events/geoInt2015/LBrown_DL.pdf

ImageNet 2014

GoogleNet


- Melhor desempenho na ImageNet em 2014 (Inception / GoogLeNet)



- C. Szegedy, W. Liu, Y. ia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich
Going Deeper with Convolutions [arXiv:1409.4842](https://arxiv.org/abs/1409.4842)

Eventos

- 2014 - Deep Face (Facebook) / LFW database



- Treinada com 4M imagens faciais

Modelo	# de parâmetros	Acurácia (%)
Deep Face	128 M	97,35
State-of-the-art [2013]	~	79,70
Nível Humano	N / A	97,50

- Y. Taigman, M. Yang, M.A. Ranzato, L. Wolf. *DeepFace: Closing the Gap to Human-Level Performance in Face Verification*. CVPR 2014.

Eventos

- 2014 - Deep Face (Facebook)
 - Frontalization



(a)



(b)



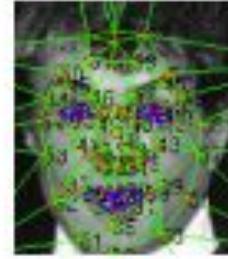
(c)



(d)



(e)



(f)



(g)




(h)

Eventos

- 2015 - FaceNet (Google-DeepMind2014)

- Acurácia em 99,63% (LFW)
- Representação Compacta
 - (128 bytes por Face)
- Usaram 100M-200M
 - De 8M de entidades




Invariância a iluminação e pose

- F. Schroff, D. Kalenichenko, J. Philbin. FaceNet: A Unified Embedding for Face Recognition and Clustering. CVPR 2015.

2015 - FaceNet - Erros

False accept



- F. Schroff, D. Kalenichenko, J. Philbin. FaceNet: A Unified Embedding for Face Recognition and Clustering. CVPR 2015.

2015 - FaceNet - Erros



- F. Schroff, D. Kalenichenko, J. Philbin. FaceNet: A Unified Embedding for Face Recognition and Clustering. CVPR 2015.

Eventos

- **2010/2013 - TIMIT Phoneme Recognition**

Modelo	# de parâmetros	Erro (%)
Hidden Markov Model (HMM)	N/A	27,3
Deep Belif Network DBN	~4M	26,7
Deep RNN	4,3M	17,7

- Dados:

- Pessoas (#): 462 *train* / 24 *test*
- Tempo (h): 3,16 *train* / 0,14 *test*

- Mohamed, A. and Hinton, G. E. (2010). Phone recognition using restricted Boltzmann machines // ICASSP pages 4354–4357.
- Graves, A., Mohamed, A.-R., and Hinton, G. E. (2013). Speech recognition with deep recurrent neural networks ICASSP, pages 6645–6649.

Eventos

- **2014 - Google Large Vocabulary Speech Recognition**
 - Data de treinamento: 3M expressões (1900 hrs)

Modelo	# de parâmetros	Cross-entropy (%)
ReLU DNN	128 M85M	11,3
Deep Projection LSTM RNN	13M	10,7

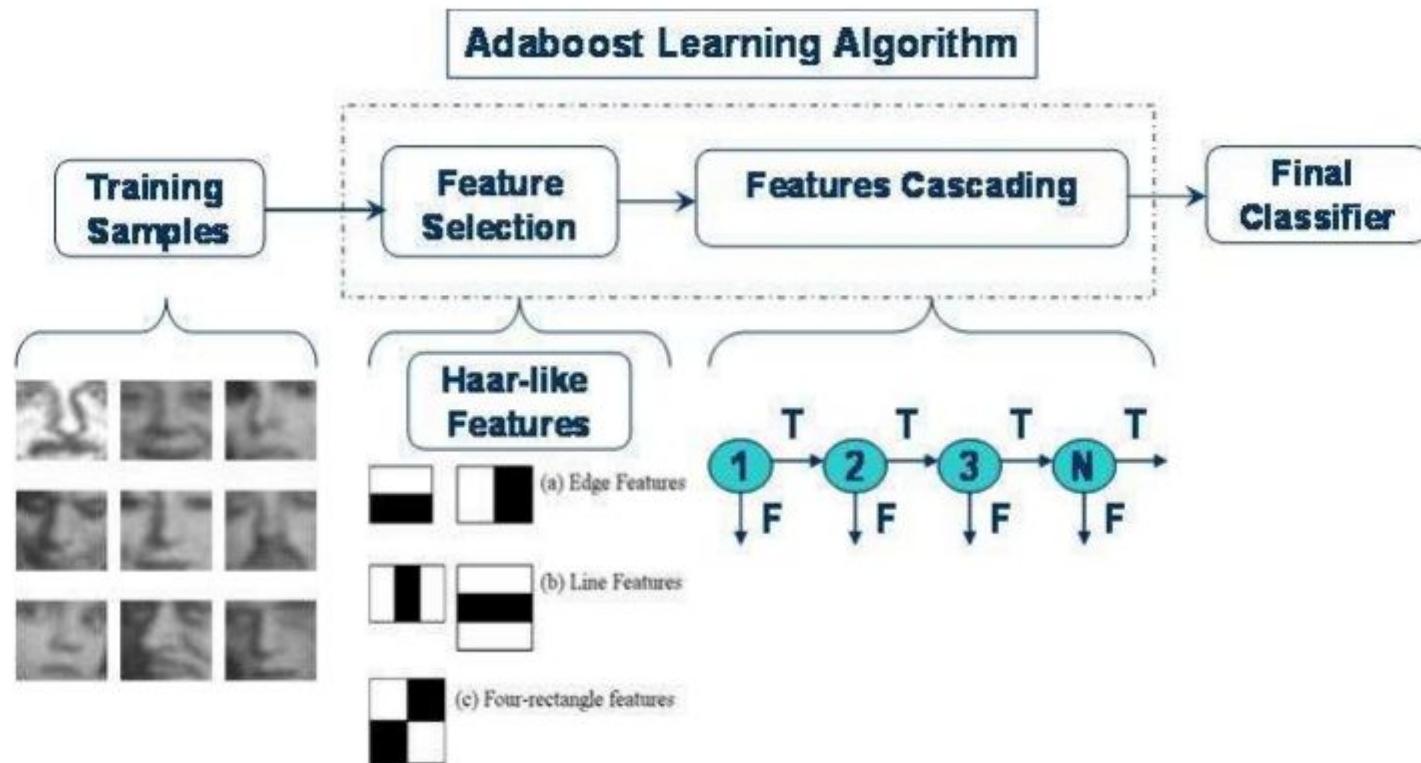
- H. Sak, A. Senior, F. Beaufays. Long Short-Term Memory Recurrent Neural Network Architectures for Large Scale Acoustic Modeling // INTERSPEECH'2014.
- K. Vesely, A. Ghoshal, L. Burget, D. Povey. Sequence-discriminative training of deep neural networks // INTERSPEECH'2014.

Inteligência Artificial

- **Processamento de Linguagem Natural (2010)**
 - Siri (Apple)
 - The Assistant (Google)
 - Microsoft (Cortana)
 - Alexa (Amazon)

Eventos

- 2001 - Face Detection - Viola & Jones

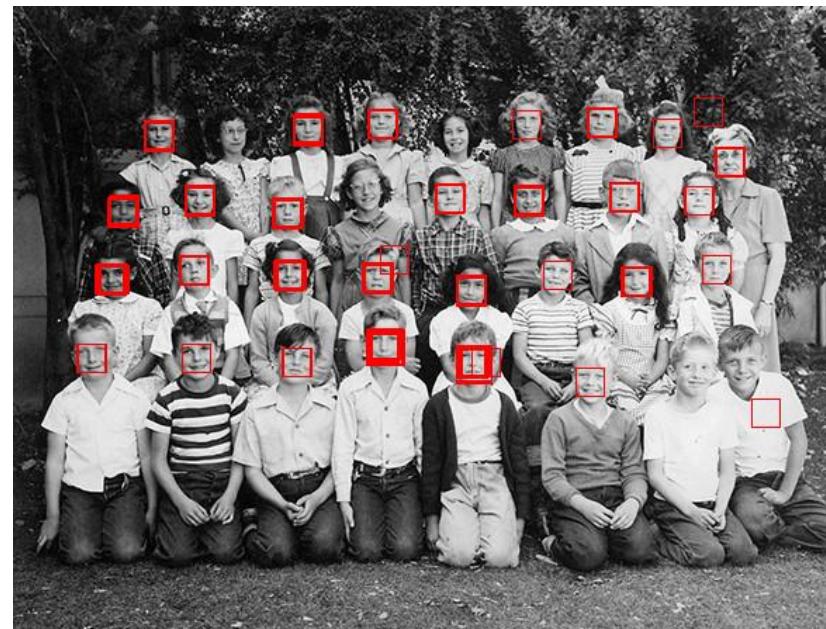
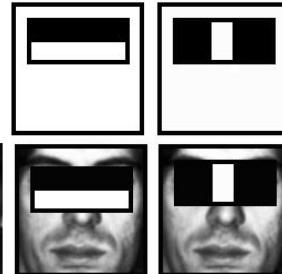


- P. Vila & Jones, Rapid object detection using a boosted cascade of simple features
IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2001

Eventos

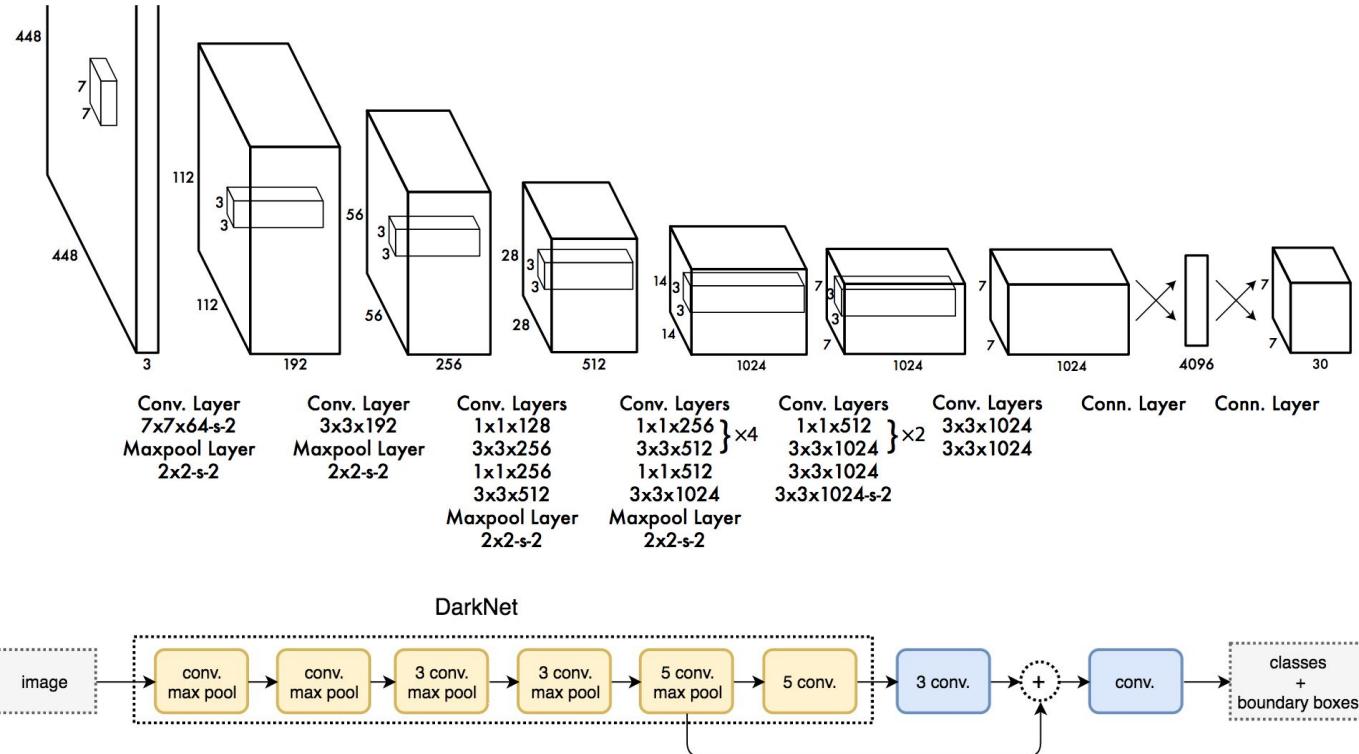
- **2001 - Object Detection - Viola & Jones**

- Semanas para treinar
 - Características simples
- Imagens de 384x288 pixels
- 15 fps 700 Mhz
 - Pentium III
- ~94 de acurácia
- Máquinas Fotogr.



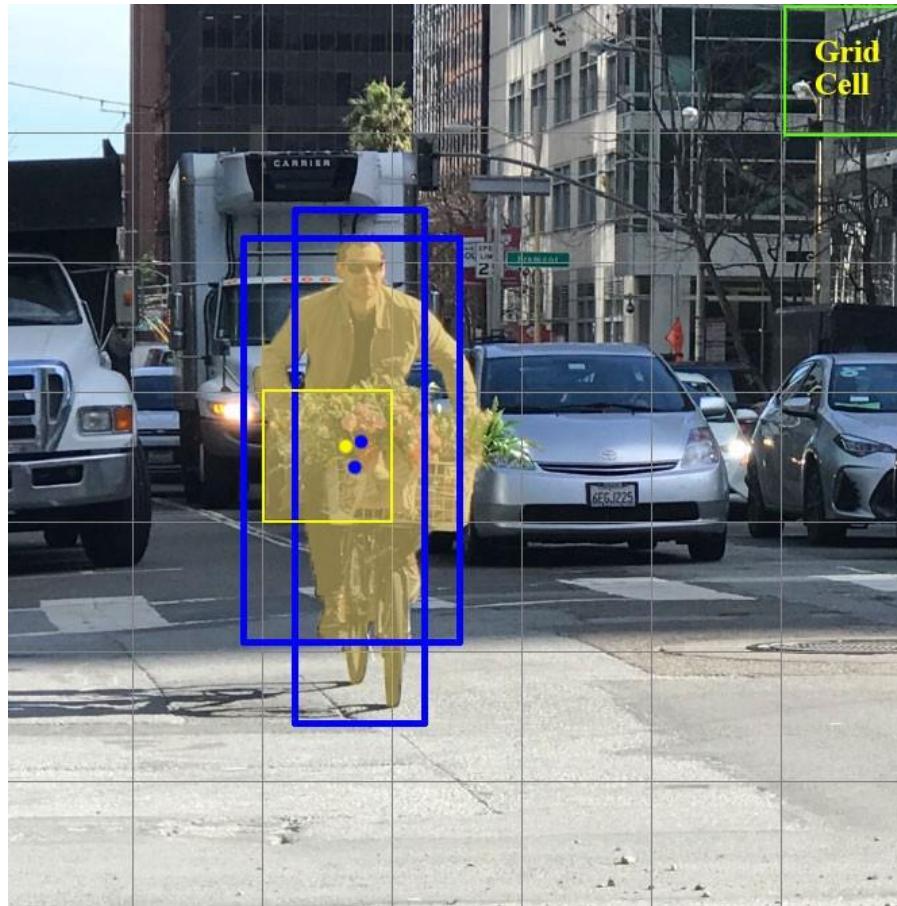
Eventos

- 2015-2017 Yolo (Object Detection)



Eventos

- 2015-2017 Yolo (Object Detection)



Object Detection

- Demonstração YoloV2 & YoloV3
 - Vídeos ~ 3 minutos

Eventos

- 2015-2018 Identificação de Veículos
 - Câmera e Veículo em movimento

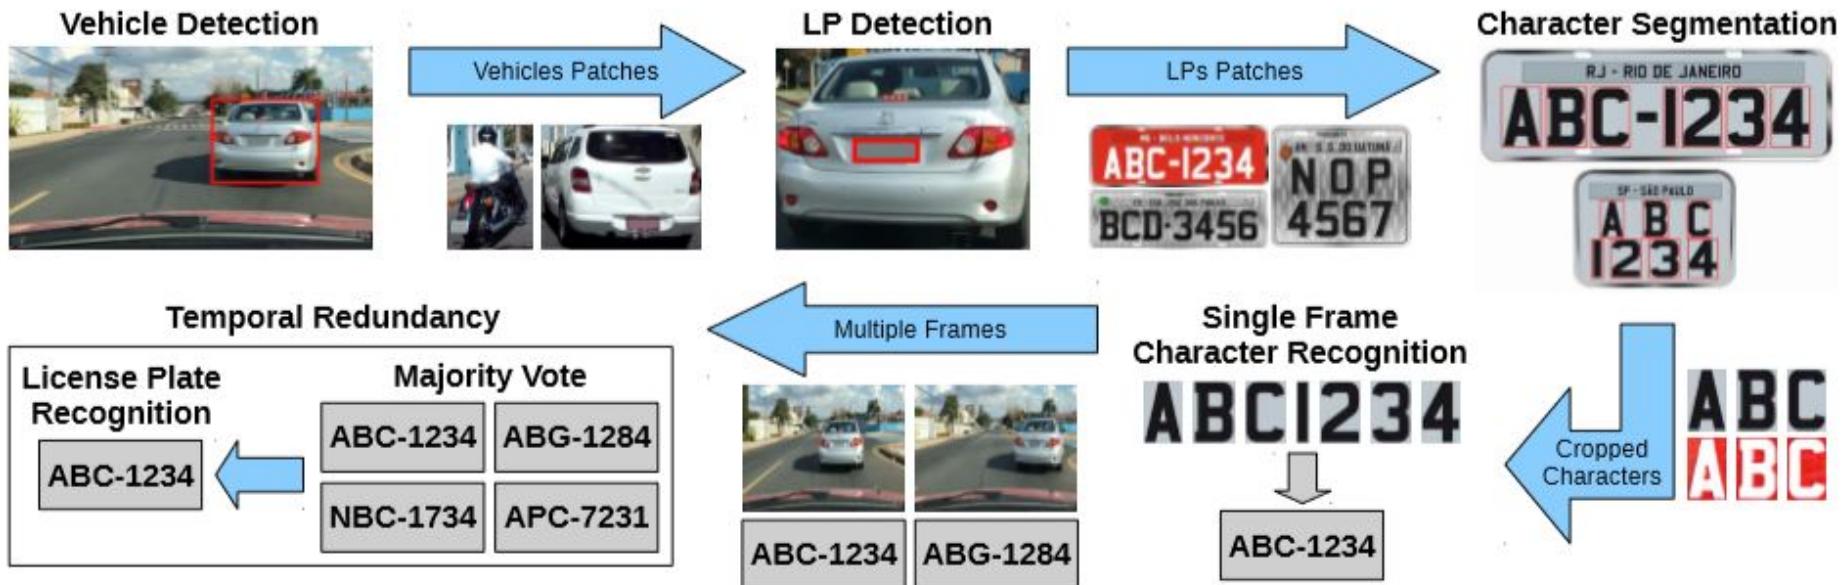


Fig. 5. An usual ALPR pipeline having temporal redundancy at the end.

- R. Laroca, others, D. Menotti, A robust real-time automatic license plate recognition based on the YOLO detector. IEEE International Joint Conference on Neural Networks (IJCNN) 2018.

Eventos

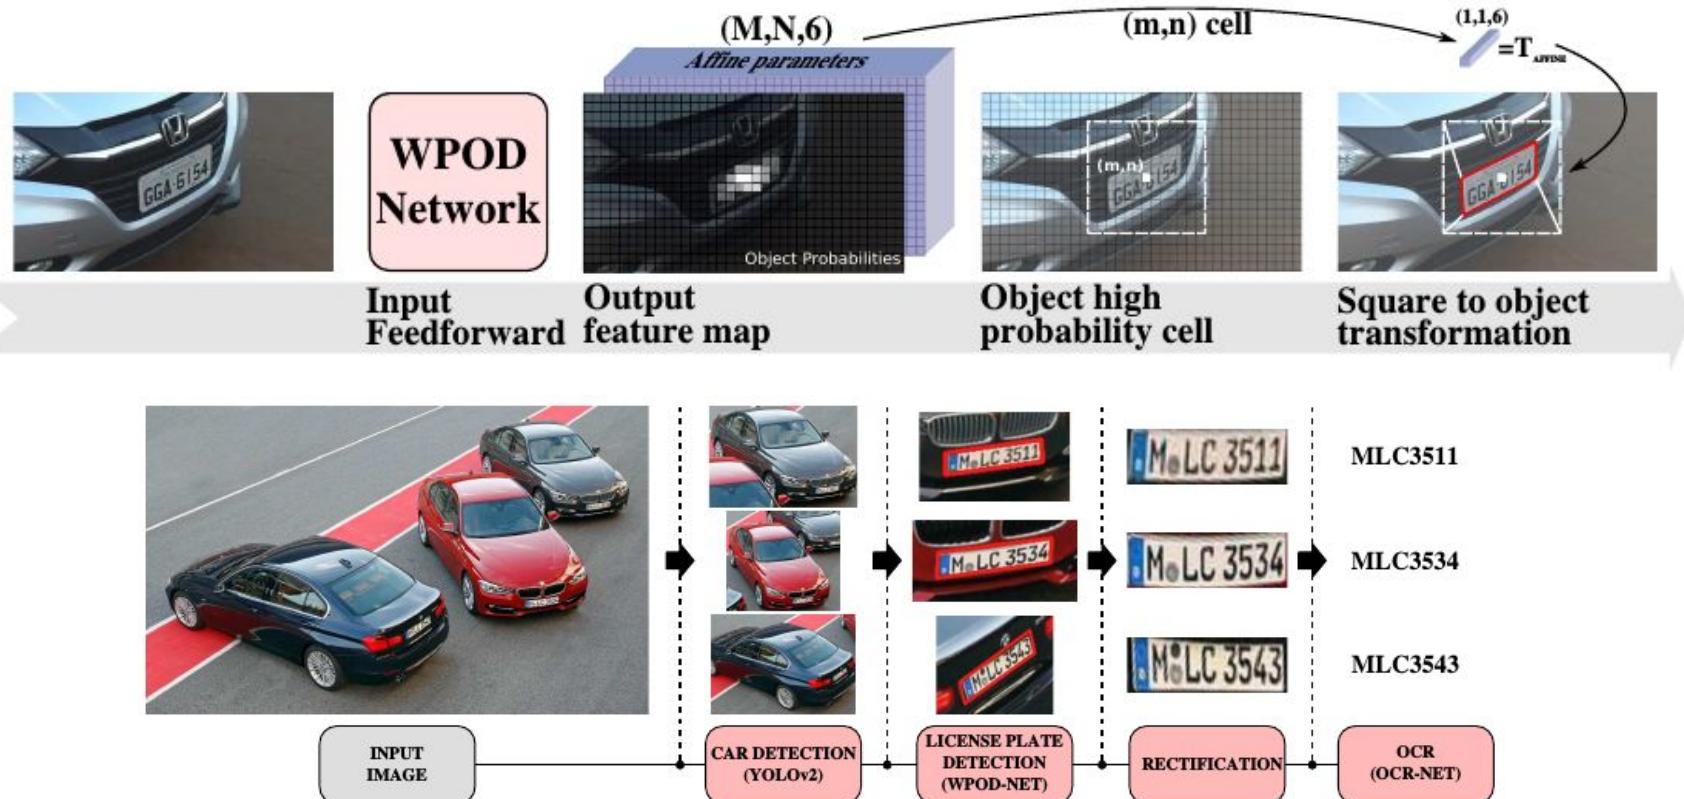
- **2015-2018 Identificação de Veículos**
 - Vídeo 1 minuto



- R. Laroca, others, D. Menotti, A robust real-time automatic license plate recognition based on the YOLO detector. IEEE International Joint Conference on Neural Networks (IJCNN) 2018.

Eventos

- 2018 Retificação da Placa



- S. Montazolli & C. R. Jung, License Plate Detection and Recognition in Unconstrained Scenarios. European Conference on Computer Vision (ECCV) 2018.

Eventos

- **2018 Identificação de Veículos**
 - Vídeo 2 minutos
 - <http://www.inf.ufrgs.br/~crjung/alpr-datasets/>



- S. Montazolli & C. R. Jung, A robust real-time automatic license plate recognition based on the YOLO detector. IEEE International Joint Conference on Neural Networks (IJCNN) 2018.

Eventos

- 2016 - AlphaGo (Image)
 - Usa conhecimento humano & experiência
 - DL vence por 4 a 1 **Lee Sedol** (echo de **Garry Kasparov**)
 - Jogo muito mais complexo que xadrez
 - Google usou 1920 CPUs & 280 GPUs



Eventos

- **2017 - AlphaGo Zero (*Reinforcement learning*)**
 - Conhece regras do jogo / sem usar dados de treinamento
 - Aprende jogando contra si mesmo,
 - Venceu AlphaGo Lee (3 dias), competitivo com AlphaGo Master (21 dias) e superou todos com 40 dias
 - 19 servidores CPU e 64 estações GPU
 - Melhor que ser humano
sem conhecimento
 - **Implicações?**
 - [Silver, David](#); Schrittwieser, Julian; Simonyan, Karen; Antonoglou, Ioannis; [Huang, Aja](#); Guez, Arthur; Hubert, Thomas; Baker, Lucas; Lai, Matthew; Bolton, Adrian; [Chen, Yutian](#); Lillicrap, Timothy; [Fan, Hui](#); Sifre, Laurent; Driessche, George van den; Graepel, Thore; [Hassabis, Demis](#) (19 October 2017). "[Mastering the game of Go without human knowledge](#)". *Nature*. **550** (7676): 354–359



Bigshots - Machine Learning

- **Geoffrey Hinton (University of Montreal)**
 - Nature em 1986
 - Backpropagation
 - Science em 2006
 - Stacker Auto-encoder
 - redução de dimensionalidade
 - Explorou ImageNet 2012
 - Lecun & Bengio

Bigshots - Machine Learning

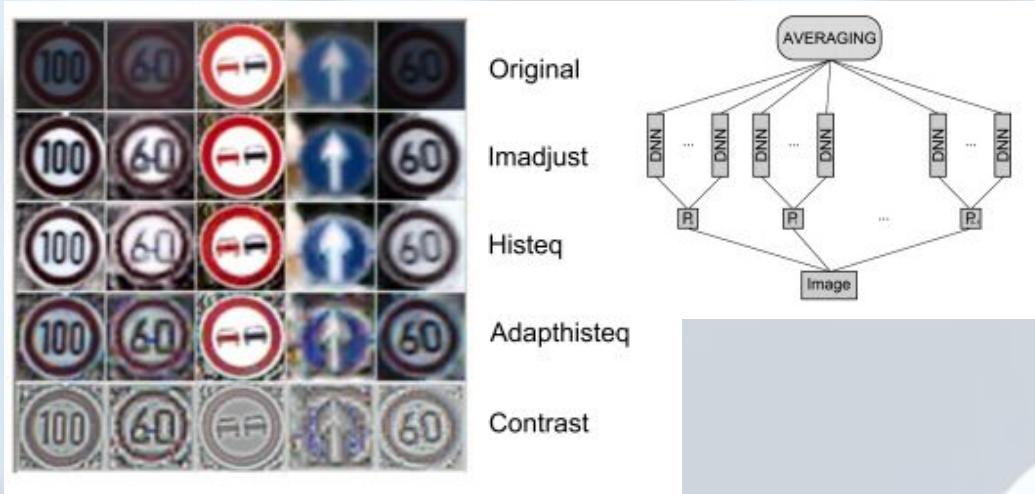
- **Yoshua Bengio - University of Montreal**
 - Trabalhos teóricos (*insights*)
 - Continua fazendo pesquisa
 - Irmão está na Google (Sammy Bengio)
 - Hinton & Bengio

Bigshots - Machine Learning

- **Yann Lecun - Facebook / NYU**
 - “Pai” da Rede de Convolução
 - 1989 Trabalho de graduação (ESIEE-Paris)
 - 1998 - Convolução para Back-propagation
 - 1991 PostDoc (University of Toronto)
 - Hinton
 - 1996 AT&T Labs - Image Processing Head
 - 2003 NYU (*New York University*)
 - 2013 - Chief AI Scientist for Facebook AI Rs
 - Hinton & Bengio

Bigshots - Machine Learning

- **Jurgen Schmidhuber (Switzerland)**
 - (Re)Clama / Questiona autorias
 - 2012 - Reconhecedor de Placas de Trânsito
Acurácia superior a de seres humanos (99,36%/98,48%)



- D. Cireşan, U. Meier, J. Masci, **Jürgen Schmidhuber**. Multi-column deep neural network for traffic sign classification, Neural Networks, 2012 (citado por 468 jul/2018)

Bigshots - Machine Learning


- **Andrew NG - (Stanford University)**
 - Aprendizado não-supervisionado dos pesos
 - Clusters (k-means) originam pesos
 - O próximo **breakthrough** está aqui ???
 - Excelente curso MOOC

Bigshots - Machine Learning

- **David Cox - Harvard / MIT**
 - Redes Imitam Cérebro
 - Experimentos com ratos
 - Não há aprendizado de pesos, mas sim otimização da arquitetura
 - Tamanhos das camadas da Rede relacionadas a estrutura cerebral
 - Pesos com Padrão (Média Zero e Norma Unitária)
 - **Nicolas Pinto** - Alta-performance (GPU)

Bigshots - Machine Learning

- **David Cox - Harvard / MIT**
 - Cérebro & Redes de Convolução





Referências

- James O'Malley **The 10 most important breakthroughs in Artificial Intelligence**
<https://www.techradar.com/news/the-10-most-important-breakthroughs-in-artificial-intelligence>
- Seth Weidman **The 4 Deep Learning Breakthroughs You Should Know About**
<https://towardsdatascience.com/the-5-deep-learning-breakthroughs-you-should-know-about-df27674ccdf2>
- Artem Chernodub, Geroge Pashchenko, **Details of Lazy Deep Learning for Images Recognition in ZZ Photo app**, Kharkob AI Club, 2015
- Alex Oagana **A Short History of Mercedes-Benz Autonomous Driving Technology**
<https://www.autoevolution.com/news/a-short-history-of-mercedes-benz-autonomous-driving-technology-68148.html>