

# Tema 8 - cont.


## Redes Neurais Artificiais MLP's e *deep learning*

Professora:

Ariane Machado Lima

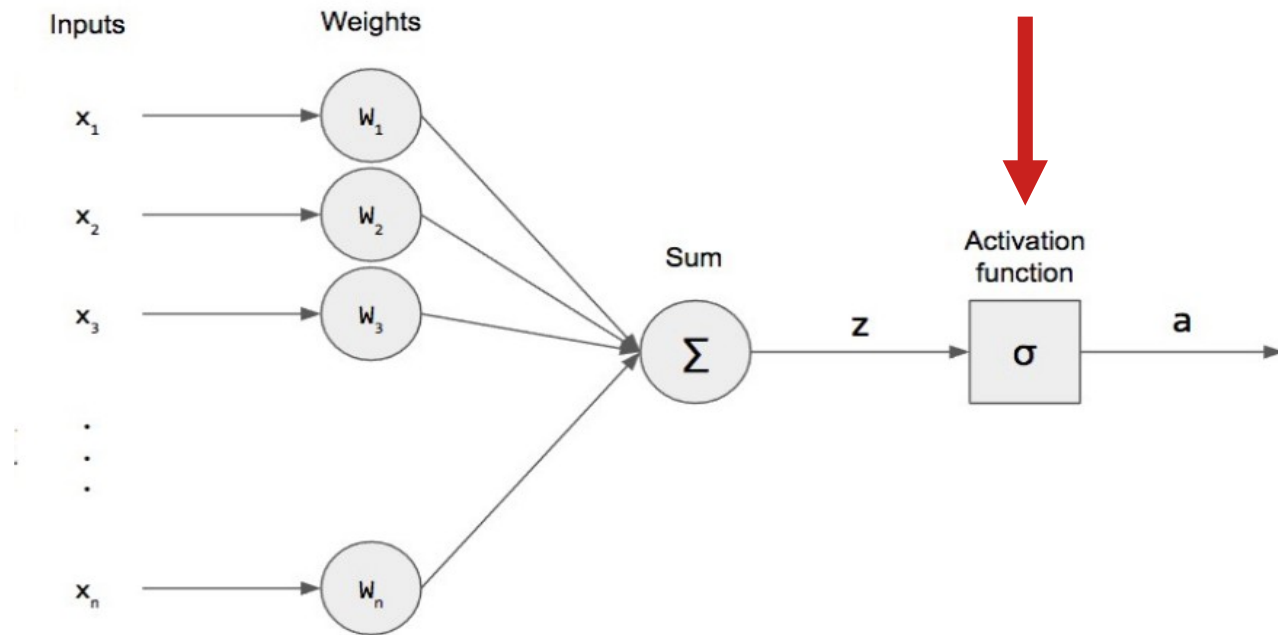
# MLP's e *Deep Learning*

- Aprendizado profundo: MLP de muitas camadas
- Não necessariamente todas as camadas ocultas são completamente conectadas como em MLP's tradicionais (veremos superficialmente algumas arquiteturas)
- Muitas questões em comum – veremos isso primeiro



# Funções de ativação


# Funções de ativação



- Em MLPs precisa ser diferenciável (não pode ter saltos)
- As mais comuns: (é um hiperparâmetro a ser calibrado)
  - linear
  - relu
  - sigmóide ou logística
  - tangente hiperbólica
  - softmax


# Função de ativação linear

Linear Activation Function



- $f(x) = x$
- “identity” no sklearn
- Usada quando se quer aprender funções lineares
- Em algumas camadas em algumas arquiteturas

# Função de ativação relu (Rectified Linear Unit )





- $f(x) = \max(0, x)$
- “relu” no sklearn
- Muito usada nas camadas ocultas de redes profundas
  - cálculo rápido
  - sofre menos de desvanecimento do gradiente (sem precisar ser linear)
  - famosas em CNNs (imagens: valores de pixels devem ser sempre positivos)
  - inativa alguns neurônios (sempre produzem 0) → pode ser bom para evitar *overfitting* (mas pode inativar demais, por isso há variações da relu)

Boa para classificação e regressão

# Função de ativação sigmóide ou logística

- $f(x) = 1 / (1 + e^{-x})$
- “logistic” no sklearn
- Transforma a entrada em um valor entre 0 e 1
- Lembra a função degrau: usada em **classificação binária**, principalmente na camada de saída (se valor  $\geq 0.5 \rightarrow$  classe +)
- É ela que o sklearn usa na camada de saída para classificação binária, deixando você escolher mudar apenas a das camadas ocultas





# Função de ativação tangente hiperbólica



- $f(x) = \tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$
- “tanh” no sklearn
- Similar à sigmoide, mas transforma a entrada em um valor entre -1 e 1
- Útil quando há dados negativos (que na sigmóide dariam 0, e poderiam prejudicar o treinamento)
  - Note que isso tem a ver com como você normalizou seus dados... (ruim para min-max, bom para z-score)
- Também pode usada em **classificação binária**:
  - na camada de saída se valor  $\geq 0 \rightarrow$  classe +)
  - escolha interessante: tanh nas camadas ocultas e sigmoide na camada de saída



# Função de ativação softmax

- $f(x)_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$
- Não tem no sklearn (como opção para a camada oculta – veremos o porquê)
- Similar à sigmoide (transforma a entrada em um valor entre 0 e 1)
- Usada na última camada para **classificação multiclasse**:
  - não é executada em cada neurônio de saída, mas em todos (de saída) ao mesmo tempo
  - para n classes, n neurônios de saída
  - recebe como entrada um vetor de tamanho n (os resultados de cada neurônio de saída - soma ponderada que chega em cada um) e gera como resultado um vetor de tamanho n (cada componente  $i$  do vetor de é a probabilidade da classe  $i$ )

## Softmax Function



# Funções de perda

# Funções de perda (ou funções custo)


- Usadas para medir o erro da rede
- Treinamento da rede → Otimização dos parâmetros para minimização da função de perda
- Há ainda os algoritmos otimizadores para fazer isso. Ex:
  - SGD (Stochastic Gradient Descent)
  - Adam

# Diferentes funções de perda para diferentes tarefas

- Regressão: mínimos quadrados (MSE) ou MAE (*mean absolute error*)
- Classificação: entropia cruzada média (*average cross-entropy*) ou *log loss function*
- Existem outras...

# Entropia cruzada (*log loss*)

- Em classificação binária:
  - Um neurônio de saída, que fornece a probabilidade da classe ser positiva
  - Uma boa função de perda deve dar um valor baixo para previsões **boas** (probabilidades altas para instâncias positivas, ou probabilidades baixas para instâncias negativas) e alto para previsões **ruins** (probabilidades altas para instâncias negativas, ou probabilidades baixas para instâncias positivas)
- É o que faz a entropia cruzada




# Entropia cruzada MÉDIA (*log loss*)

$$H(y, \hat{y}) = -\frac{1}{n} \sum_{i=0}^n (y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i))$$

- $y_i$  é a classe da  $i$ -ésima instância (1 para a classe positiva e 0 para a classe negativa)
- $\hat{y}_i$  = probabilidade dada pela rede da  $i$ -ésima instância ser positiva
- Como é função de perda, quanto menor melhor; como tem um “-” multiplicando, quanto maior o conteúdo do somatório melhor, então:
  - Favorece altas probabilidades da classe positiva e baixas probabilidades da classe negativa

# Entropia cruzada MÉDIA (*log loss*)

$$H(y, \hat{y}) = -\frac{1}{n} \sum_{i=0}^n (y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i))$$




# Entropia cruzada MÉDIA (*log loss*)

$$H(y, \hat{y}) = -\frac{1}{n} \sum_{i=0}^n (y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i))$$

- Note que a entropia cruzada compara duas distribuições de probabilidades:  $y$  e  $\hat{y}$ , que no caso de classificação binária ambas são Bernoulli (por isso a “cara” da equação acima: “ $p$  e  $(1-p)$ ”)
- Se a classificação for multiclasse, as distribuições (sobre as classes) são multinomiais



# Entropia cruzada MÉDIA (*log loss*)



- Em classificação multiclasse:
  - $c$  neurônios de saída (para  $c$  classes)
  - Neurônio de saída  $j$ : probabilidade da classe  $j$
  - $y_i$ : probabilidades reais da instância  $i$ :
    - $(1, 0, \dots, 0)$  para a classe 1
    - $(0, 1, \dots, 0)$  para a classe 2
    - ...
    - $(0, 0, \dots, 1)$  para a classe  $c$

- $$H_p(q) = -1/n \sum_{i=1}^n \sum_{j=1}^c y_{i(j)} \log(\hat{y}_{i(j)})$$

# Clareando alguns termos

- Há nomes específicos para a combinação de função perda de entropia cruzada (EC) + uma função de ativação para classificação (camada de saída)
- Entropia cruzada binária: classificação binária
  - EC + sigmóide
- Entropia cruzada categórica: classificação multiclasse:
  - EC + softmax

# Regularização

- Técnicas para evitar overfitting
- Em MLP's (principalmente as profundas), adiciona-se um termo na função perda que penaliza valores altos (em módulo) dos pesos
- Regularização L1:  $\alpha \sum |w_i|$
- Regularização L2:  $\alpha \sum w_i^2$  (usada no sklearn)

# Early stopping

- Usualmente o treinamento pára quando a função perda não mais diminui após um certo número de iterações (usando a própria amostra de treinamento)
- Ao invés disso, pode-se usar uma amostra de validação para fazer isso (early stop)
- No sklearn, separa automaticamente 10% da amostra de treinamento se setar essa opção
- Tentativa extra de evitar *overfitting*

# Comentários sobre *Deep Learning*


Redes neurais PROFUNDAS:

- } muitas camadas ocultas
- } diferentes arquiteturas (formato das camadas ocultas)
- } lado positivo: dados “brutos” ao invés de características selecionadas
- } lado negativo: necessita de MUITOS dados para treinamento do modelo
- } logo, não é para tudo...


#training images	VAL
2,600,000	76.3%
26,000,000	85.1%
52,000,000	85.1%
260,000,000	86.2%

Ex: FaceNet (700h de treinamento para o modelo menor... - 1 mês)  
 VAL: taxa de identificações corretas  
<https://arxiv.org/pdf/1503.03832.pdf>

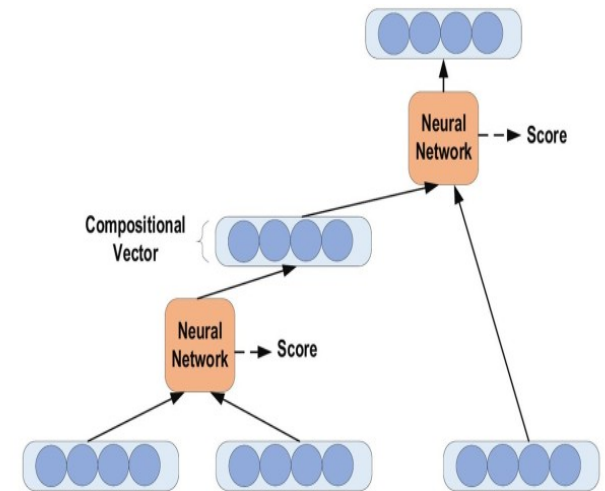
Exemplos de arquiteturas:



Rede neural completamente conectada



Rede neural recorrente




Rede neural recursiva

# Aprendizado profundo - Deep Learning

## Finetuning - transferência de aprendizado

- Treinamento da rede com um grande volume de dados mais gerais - rede **pré-treinada** (ex: faces, textos em geral)
- Adição de mais algumas camadas (no final) treinadas com dados específicos - **finetuning** (ex: dismorfismos faciais, notícias ver

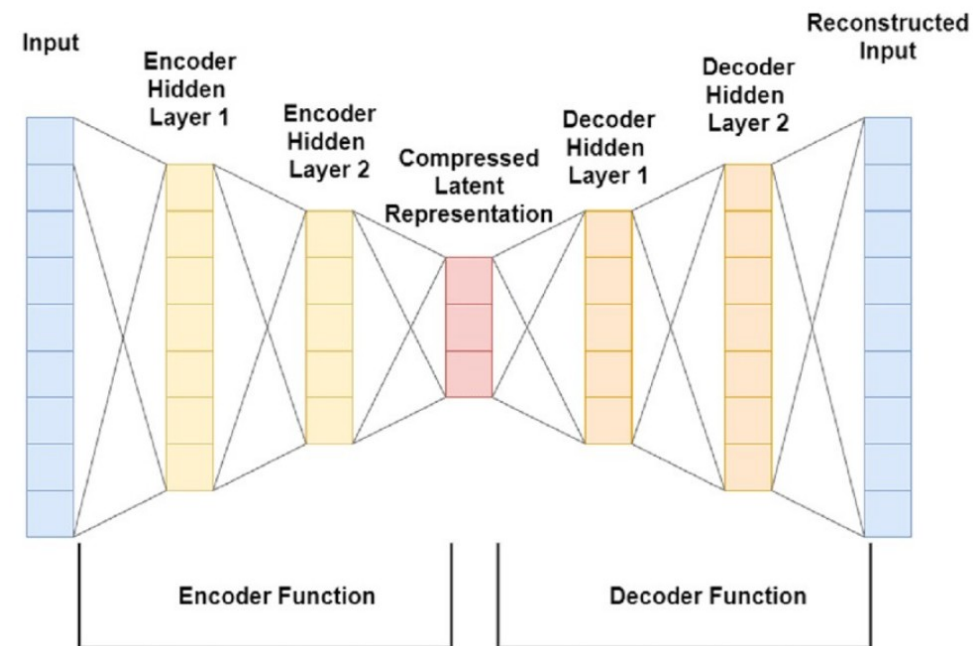


# Algumas arquiteturas

# Autoencoders

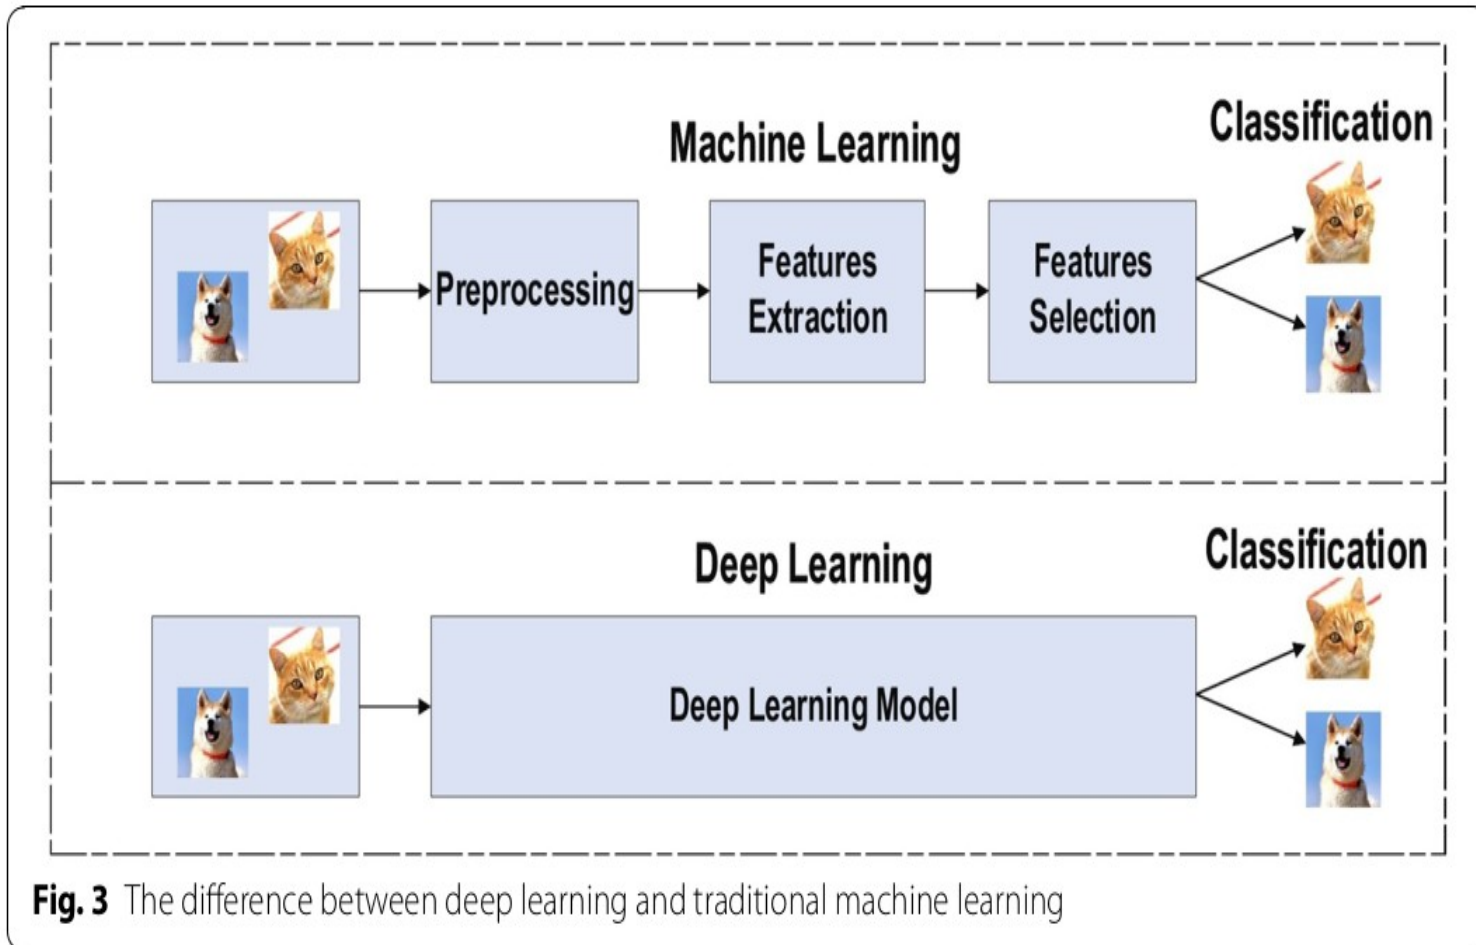
- Não supervisionado
- Usado em:

- redução de dimensionalidade
- compressão e restauração (ex: imagens)
- remoção de ruído e restauração de imagens
- ...





# Deep learning em imagens: Redes convolucionais (CNN - Convolutional Neural Networks)




**Fig. 3** The difference between deep learning and traditional machine learning

Alzubaidi et al. *J Big Data* (2021) 8:53  
<https://doi.org/10.1186/s40537-021-00444-8>

# Deep learning em imagens:

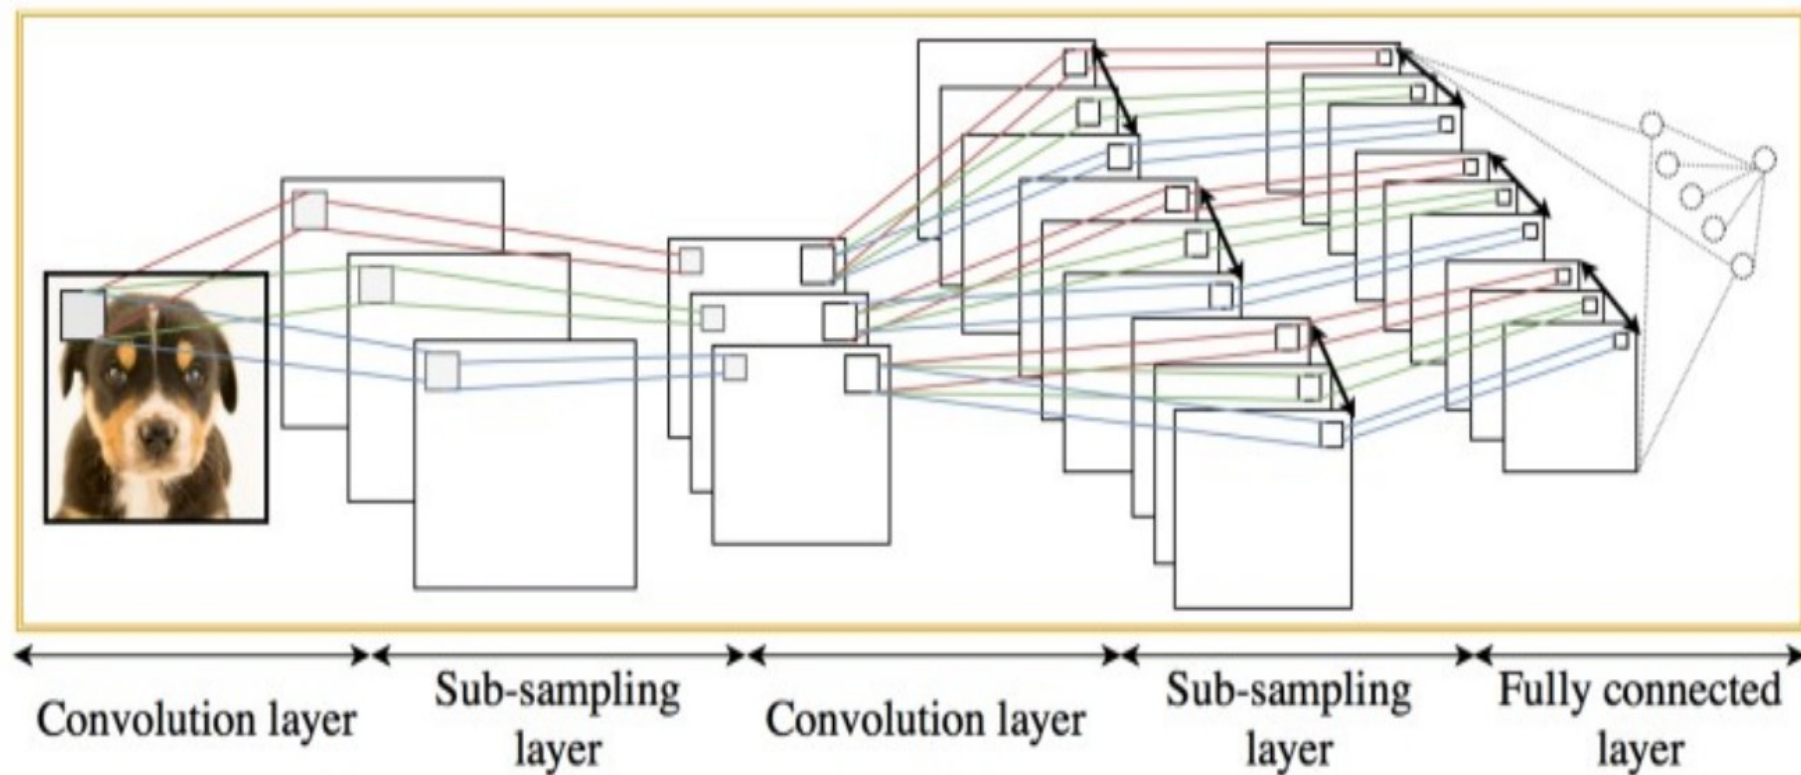
## Redes convolucionais (CNN - *Convolutional Neural Networks*)

- Muito usada para imagens. Por quê?
- Apenas fazer com que a imagem vire um vetorzão para depois alimentar a rede neural causaria perda de informação (dependências espaciais entre os pixels)



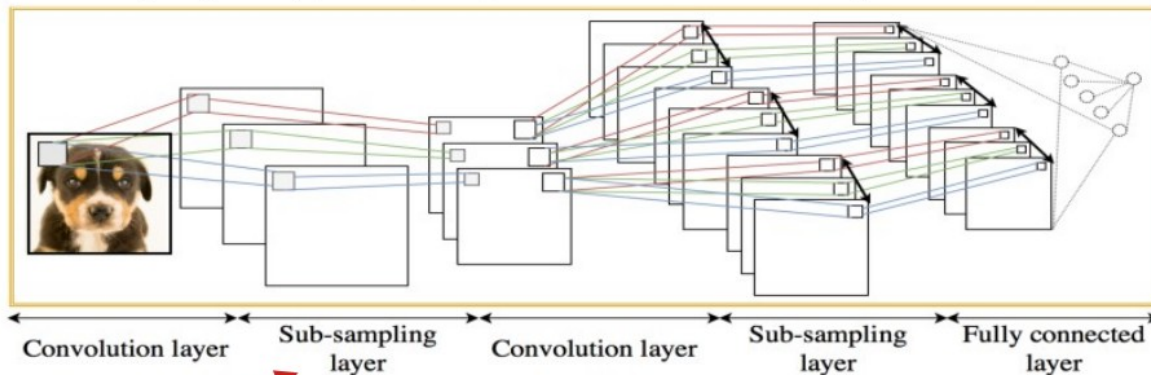
# Deep learning em imagens: **Redes convolucionais** (CNN - *Convolutional Neural Networks*)

ACM Computing Surveys, Vol. 51, No. 5, Article 92. Publication date: September 2018.




# Deep learning em imagens: **Redes convolucionais** (CNN - *Convolutional Neural Networks*)

ACM Computing Surveys, Vol. 51, No. 5, Article 92. Publication date: September 2018.



- Max-Pooling e Average Pooling
- Deslocamento (stride) = 1 não sub-amostra
- Perde-se a localização exata da informação, mas captura sua presença

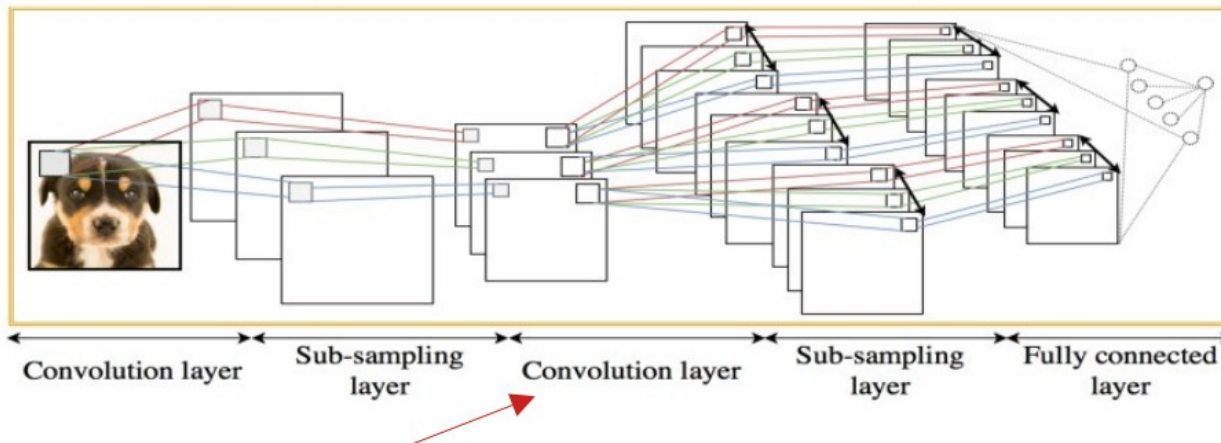


978-1-5386-1949-0/17



# Deep learning em imagens: Redes convolucionais (CNN - *Convolutional Neural Networks*)


ACM Computing Surveys, Vol. 51, No. 5, Article 92. Publication date: September 2018.



- Extração de características
- Função de convolução (kernel)

Multiplica a janela pixel a pixel  
A soma dá o novo valor do centro  
Desliza uma posição

Input image



Convolution Kernel

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

Feature map



Kernel/Filter, K =

$$\begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

1	1	1	0	0
0	1	1	1	0
0	0	1 <sub>x1</sub>	1 <sub>x0</sub>	1 <sub>x1</sub>
0	0	1 <sub>x0</sub>	1 <sub>x1</sub>	0 <sub>x0</sub>
0	1	1 <sub>x1</sub>	0 <sub>x0</sub>	0 <sub>x1</sub>

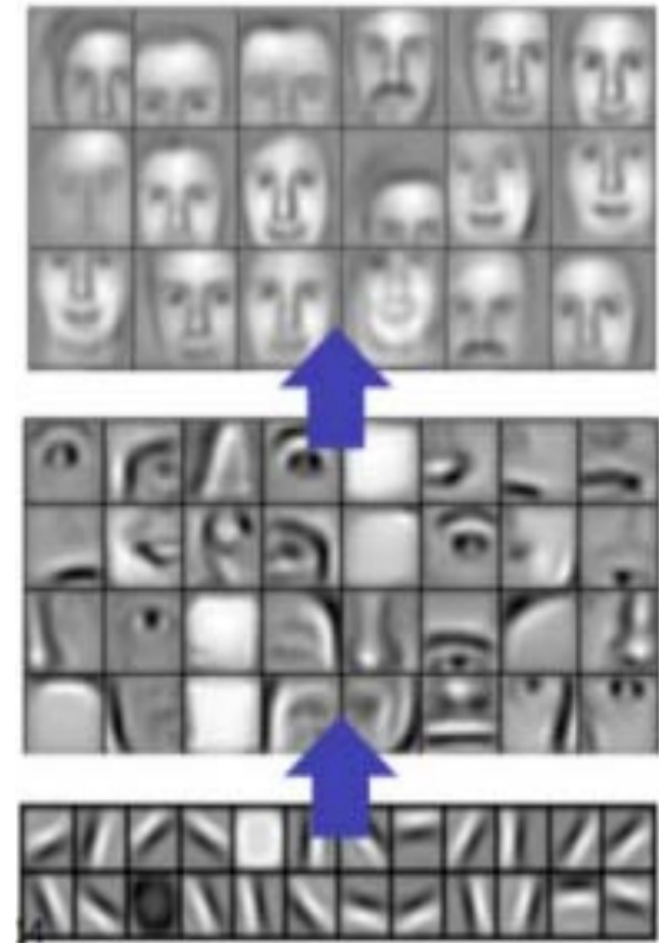
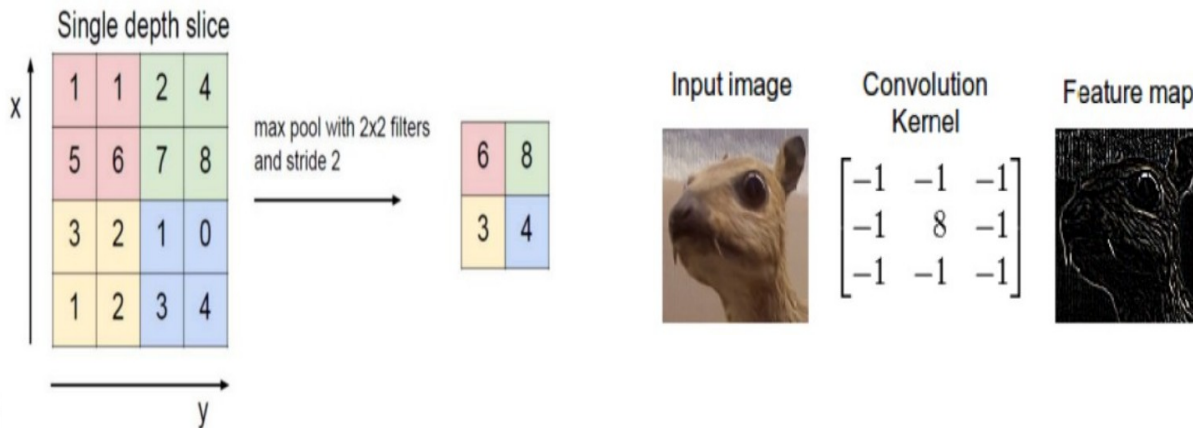
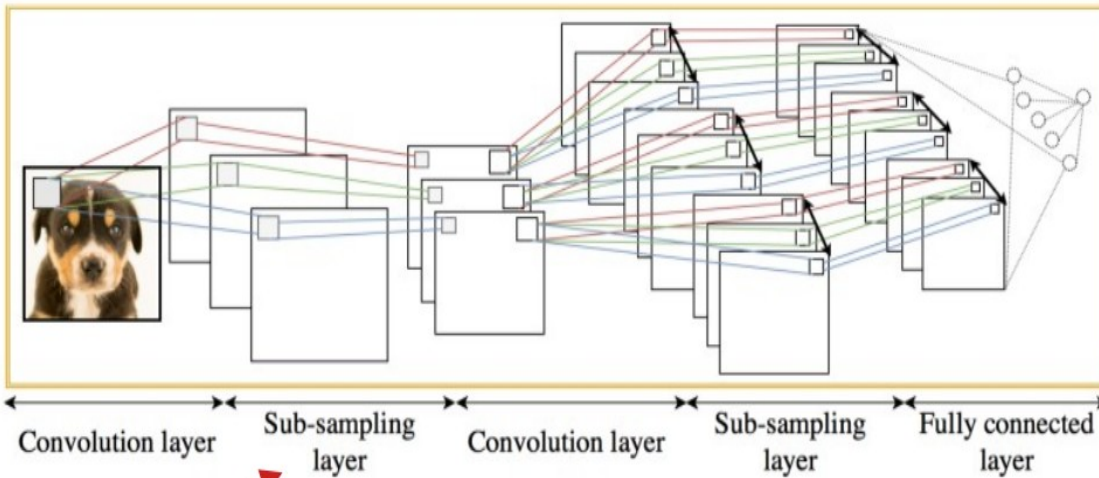
Image

4	3	4
2	4	3
2	3	4

Convolved Feature

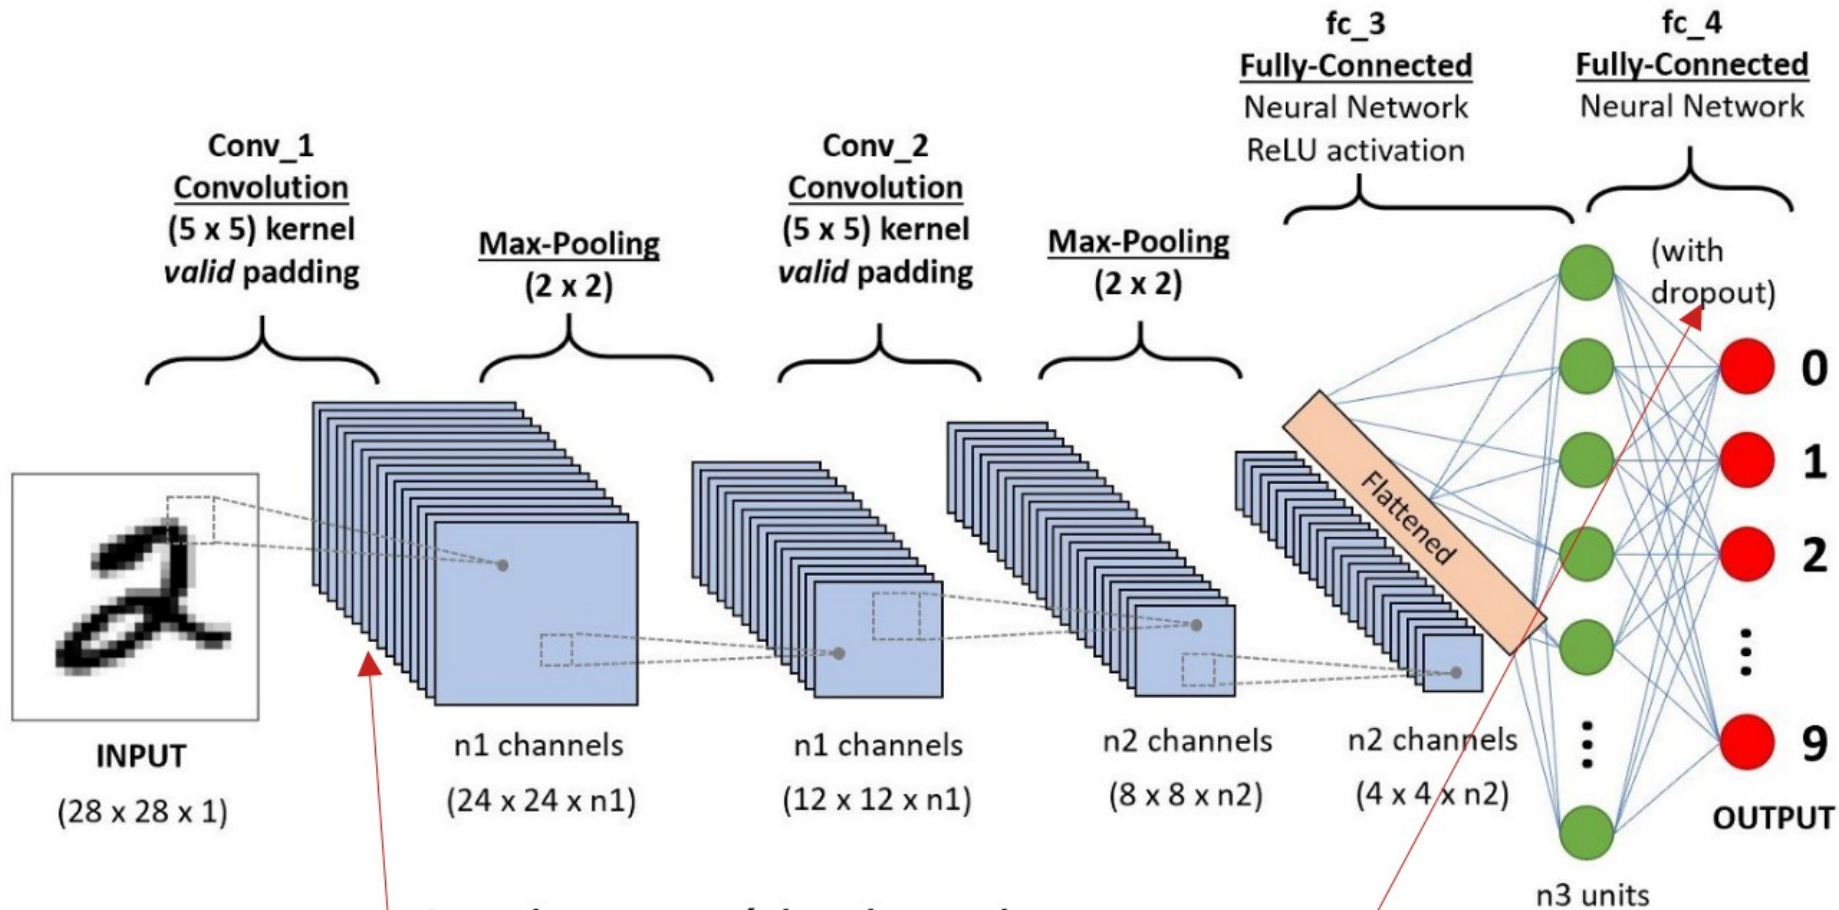
# Deep learning em imagens: Redes convolucionais (CNN - Convolutional Neural Networks)

ACM Computing Surveys, Vol. 51, No. 5, Article 92. Publication date: September 2018.



978-1-5386-1949-0/17

# Deep learning em imagens: Redes convolucionais (CNN - Convolutional Neural Networks)

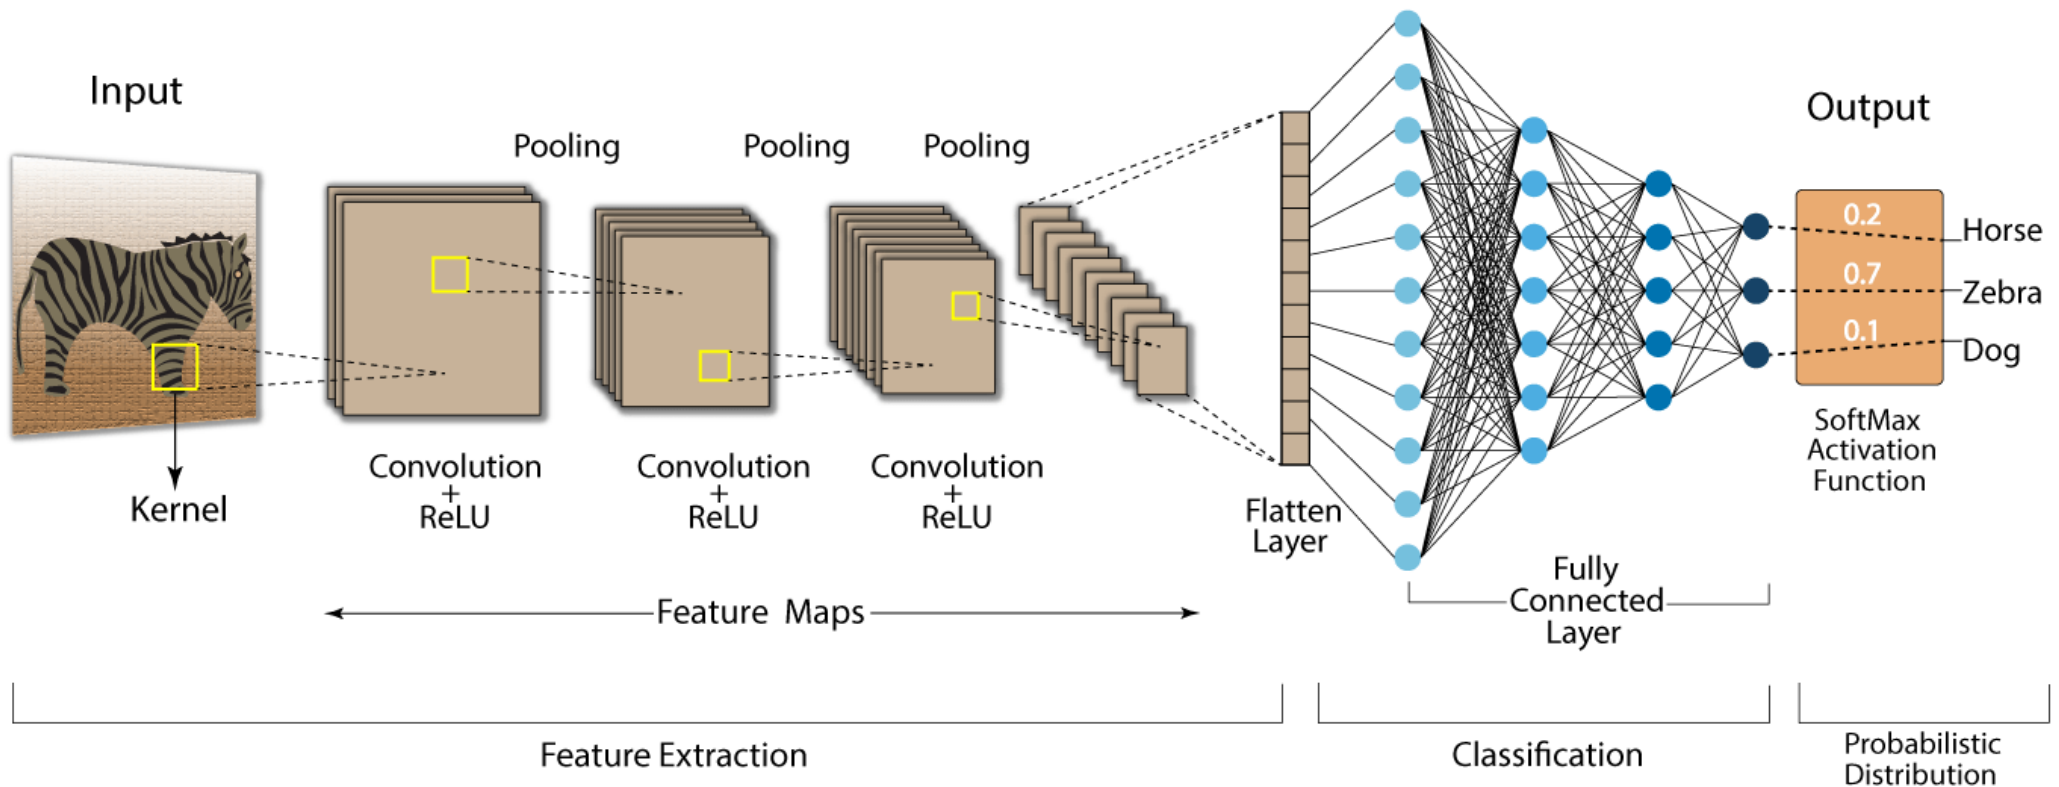


Geralmente vários kernels

E ainda posso colocar Dropout

# Deep learning em imagens: **Redes convolucionais** (CNN - *Convolutional Neural Networks*)

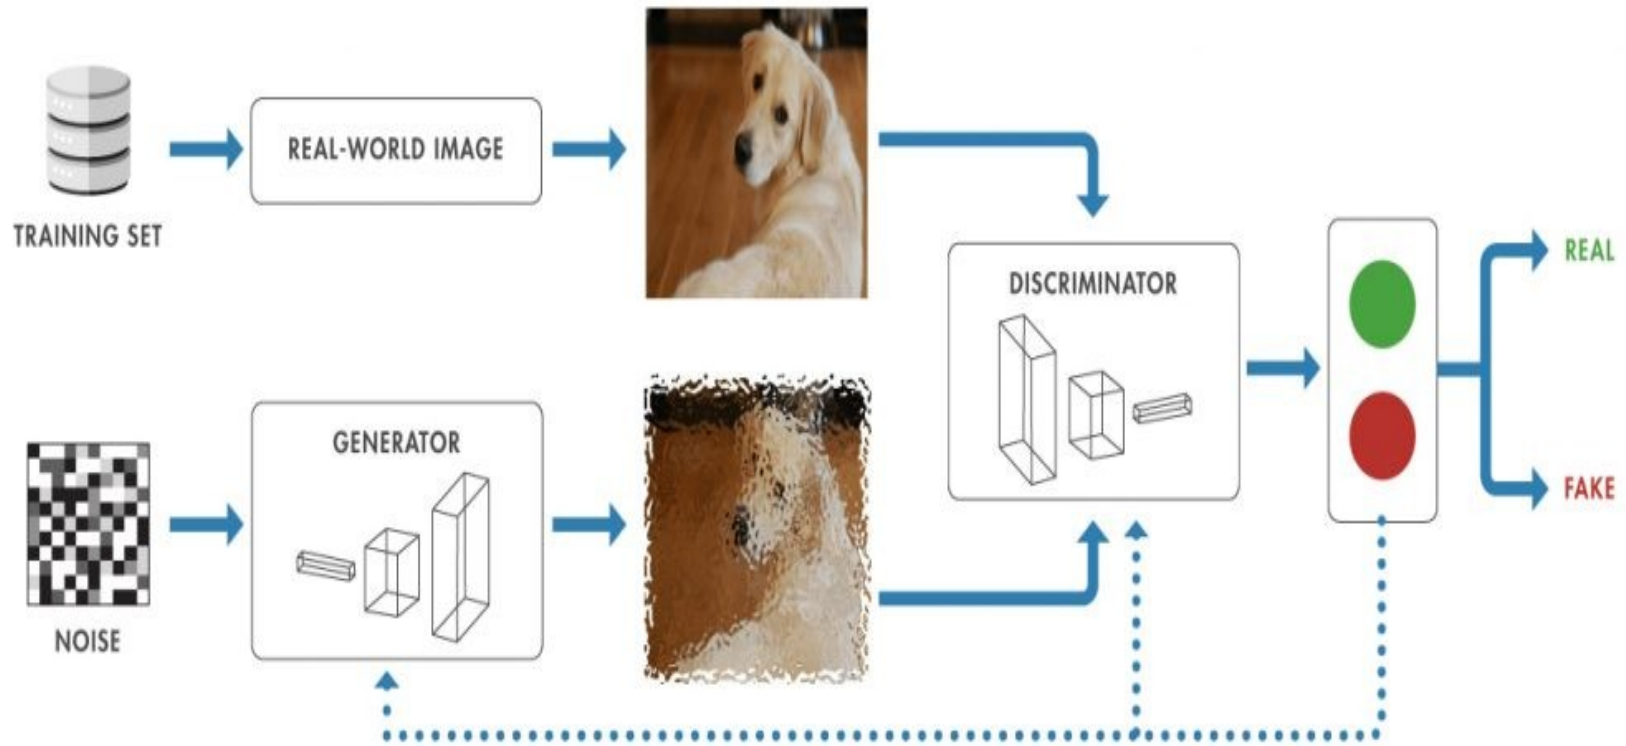
## Convolution Neural Network (CNN)



<https://www.analyticsvidhya.com/blog/2022/03/basics-of-cnn-in-deep-learning/>



# Deep learning em imagens: Redes geradoras adversárias (GAN - *Generative Adversarial Networks*)



[https://  
shorturl.at/hprt9](https://shorturl.at/hprt9)

# Deep fake




<https://i.imgur.com/jKpckyM.mp4>

<https://i.imgur.com/jKpckyM.mp4>



# Redes Neurais Recorrentes

- Para dados sequenciais (em que o contexto é importante, como em processamento de linguagem natural)



ACM Computing Surveys, Vol. 51, No. 5, Article 92. Publication date: September 2018.



# O que é o ChatGPT?

- GPT: *Generative Pre-trained Transformer* (transformador pré-treinado gerador)
- É um LLM (*Large Language Model*) - modelo (grande) de língua
- Área mista de Inteligência Artificial (IA) e Processamento de Língua Natural (PLN)

# Processamento de língua natural



# O que é um modelo de língua?

- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
-

# O que é um modelo de língua?

- “Um modelo de **língua** é um modelo que permite associar uma probabilidade **a** uma sequência de **palavras** da **língua** modelada” (Jurafsky & Martin, 2020)
  - } Treinados a partir de uma grande quantidade de textos (*córpus*)
  - } Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - } Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - } **Bag-of-words**: cada palavra tem sua probabilidade baseada na sua frequência no *córpus* (independente do entorno).
    - Ex:  $P(\text{“a”}) = 1/20$ ;  $P(\text{“língua”}) = 2/20$ ;  $P(\text{“é”}) = 1/20$ ;  $P(\text{“palavras”}) = 1/20$
    - $P(\text{“a língua é palavras”}) = 1/20 * 2/20 * 1/20 * 1/20 = 0,0000125$
    - Probabilidades utilizadas por ex. para classificação de textos



# O que é um modelo de língua?

- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - › **N-gramas**: sequência de n palavras (por ex; trigramas):
  - › “Um modelo de língua é um modelo que permite associar uma probabilidade a uma...”

# O que é um modelo de língua?

- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - › **N-gramas**: sequência de n palavras (por ex; trigramas):
  - › “Um modelo de língua é um modelo que permite associar uma probabilidade a uma...”

# O que é um modelo de língua?

- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - › **N-gramas**: sequência de n palavras (por ex; trigramas):
  - › “Um modelo de língua é um modelo que permite associar uma probabilidade a uma...”

# O que é um modelo de língua?

- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - › **N-gramas**: sequência de n palavras (por ex; trigramas):
  - › “Um modelo de língua é um modelo que permite associar uma probabilidade a uma...”








# O que é um modelo de língua?

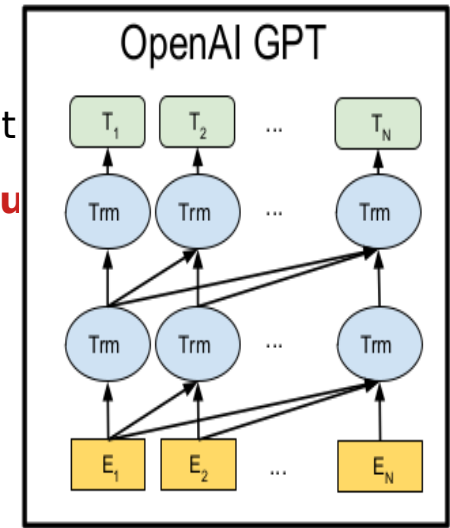
- “Um modelo de língua é um modelo que permite associar uma probabilidade a uma **sequência** de palavras da língua modelada” (Jurafsky & Martin, 2020)
  - › Treinados a partir de uma grande quantidade de textos (*córpus*)
  - › Por ex: texto azul acima: *córpus* contendo 20 palavras.
  - › Normalmente pode ser utilizado para gerar texto com base nessas probabilidades.
- Ex: *bag of words*, n-gramas e BERT são modelos (probabilísticos) de língua
  - › **BERT** (*Bidirectional Encoder Representations from Transformers*): Representações de Codificador Bidirecional a partir de Transformadores (tradução livre) - 2019
    - Uso de *word embeddings* como representação textual (“bode” fica sendo muito similar a “cabra”)
    - O contexto agora é **bidirecional** (palavras anteriores e p
    - “sequência de palavras da .... modelada”
    - “Gosto de comer .... quando estou no cinema”
    - **Modelo de atenção** (*transformer*): palavras diferentes
    - recebem pesos (atenção) diferentes durante o treiname
    - Arquitetura: rede neural profunda





# E o GPT?

- **GPT** (*Generative Pre-trained Transformer*): transformador gerador pré-treinado
  - › Conceitualmente muito similar ao BERT, mas o transformador é **unidirecional**
  - › Foco na geração de texto (da esquerda para a direita)
  - › Rede neural mais profunda (mais camadas)
  - › *Córpus* descomunal (GPT 3.5 - dados de até janeiro 2022)



- GPT e BERT são exemplos de grandes modelos de língua (**LLM - large language models**):
  - › Modelos pré-treinados (rede neural profunda) com um *córpus* gigante
  - › O contexto leva em consideração muitas posições de palavras (não as apenas duas anteriores no caso dos trigramas)
  - › Atualmente há vários outros:
    - LLaMa (Meta)
    - PaLM (Google)
    - ...

# Por que o sucesso do GPT?

- Já vimos que o GPT não é disruptivo em relação ao que já existia na época (BERT), mas utilizam mistura de especialistas e...

# Por que o sucesso do GPT?

- Já vimos que o GPT não é disruptivo em relação ao que já existia na época (BERT), mas utilizam mistura de especialistas e...

	BERT (Large)	GPT 3.5	GPT 4
Tam do <i>córpus</i> (nr de palavras)	3,3 bilhões	~1 trilhão	~13 trilhões
Nr de tokens (janela de contexto)	512	2048	32786
Nr de camadas ocultas	24	96	120
Nr total de parâmetros	340 milhões	175 bilhões	~1.8 trilhões
Hardware p/ treinamento	64 TPUs	?	25.000 GPUs (?)
Tipo de dado	texto	texto	texto e imagem

Maio de 2020: OpenAI desenvolve supercomputador: 10,000 GPUs, 285,000 núcleos de CPU

<https://news.microsoft.com/source/features/innovation/openai-azure-supercomputer/>

+ Nova conversa

GPT-3.5 GPT-4



# ChatGPT

**Crie um esquema de base de dados**  
para uma loja online de mercadorias

**Explique supercondutores**  
como se eu tivesse cinco anos de idade

**Crie um plano de treino**  
para treino de resistência

**Ajude-me a escolher**  
um presente de aniversário para a minha mãe que gos...

Envie uma mensagem

Atualize para Plus

A Ariane Machado Lima



+ Nova conversa

Default (GPT-3.5)

Hoje  
Ajuda Financeira Subpr



Eu trabalho no setor financeiro da subprefeitura do meu bairro. Em que atividades você pode ajudar?



Posso ajudar com uma variedade de tarefas relacionadas ao setor financeiro da subprefeitura do seu bairro. Algumas das maneiras pelas quais posso ser útil incluem:



1. Consultoria Financeira: Posso fornecer informações e insights sobre princípios financeiros, gestão de orçamento e estratégias financeiras.
2. Análise de Dados: Posso ajudar na análise de dados financeiros, incluindo a criação de relatórios, gráficos e interpretação de tendências financeiras.
3. Preparação de Orçamento: Posso auxiliar na criação, revisão e análise do orçamento da subprefeitura.
4. Impostos e Regulamentações: Posso fornecer informações sobre regulamentações fiscais locais e estaduais, bem como ajudar na preparação e análise de declarações de impostos.
5. Planejamento Financeiro: Posso ajudar na elaboração de planos financeiros de longo prazo, estratégias de investimento e alocação de recursos.
6. Treinamento em Ferramentas Financeiras: Posso fornecer treinamento em software financeiro, planilhas e outras ferramentas úteis para o gerenciamento financeiro.
7. Respostas a Perguntas Financeiras: Se você tiver perguntas específicas relacionadas a finanças, posso tentar fornecer respostas e orientações.

Lembrando que, embora eu possa fornecer informações e orientações, é importante consultar um especialista financeiro ou contador sempre que necessário, especialmente quando se trata de questões financeiras complexas ou regulamentações específicas da sua subprefeitura. Como minha base de conhecimento tem um limite de informações até janeiro de 2022, recomendo verificar as regulamentações mais recentes e políticas locais pa

Regenerar

Atualize para Plus

Ariane Machado Lima

Envie uma mensagem

+ Nova conversa

Default (GPT-3.5)

Hoje  
Ajuda Financeira Subpr



Eu trabalho no setor financeiro da subprefeitura do meu bairro. Em que atividades você pode ajudar?



Posso ajudar com uma variedade de tarefas relacionadas ao setor financeiro da subprefeitura do seu bairro. Algumas das maneiras pelas quais posso ser útil incluem:



1. Consultoria Financeira: Posso fornecer informações e insights sobre princípios financeiros, gestão de orçamento e estratégias financeiras.
2. Análise de Dados: Posso ajudar na análise de dados financeiros, incluindo a criação de relatórios, gráficos e interpretação de tendências financeiras.
3. Preparação de Orçamento: Posso auxiliar na criação, revisão e análise do orçamento da subprefeitura.
4. Impostos e Regulamentações: Posso fornecer informações sobre regulamentações fiscais locais e estaduais, bem como ajudar na preparação e análise de declarações de impostos.
5. Planejamento Financeiro: Posso ajudar na elaboração de planos financeiros de longo prazo, estratégias de investimento e alocação de recursos.
6. Treinamento em Ferramentas Financeiras: Posso fornecer treinamento em software financeiro, planilhas e outras ferramentas úteis para o gerenciamento financeiro.
7. Respostas a Perguntas Financeiras: Se você tiver perguntas específicas relacionadas a finanças, posso tentar fornecer respostas e orientações.

Lembrando que, embora eu possa fornecer informações e orientações, é importante consultar um especialista financeiro ou contador sempre que necessário, especialmente quando se trata de questões financeiras complexas ou regulamentações específicas da sua subprefeitura. Como minha base de conhecimento tem um limite de informações até janeiro de 2022, recomendo verificar as regulamentações mais recentes e políticas locais pa

Regenerar

Envie uma mensagem

Atualize para Plus

Ariane Machado Lima



+ Nova conversa

Hoje  
Ajuda Financeira Subpr



Me fale mais sobre os tipos de gráficos que posso gerar.



Você pode gerar diversos tipos de gráficos para representar dados financeiros ou informações relacionadas ao setor financeiro da subprefeitura do seu bairro. Cada tipo de gráfico é mais adequado para diferentes tipos de dados e propósitos. Aqui estão alguns dos tipos de gráficos mais comuns que podem ser úteis no contexto financeiro:



1. Gráfico de Barras:
  - Gráfico de barras verticais e horizontais.
  - Usado para comparar quantidades entre diferentes categorias.
  - Útil para representar o orçamento anual por categoria, despesas mensais, etc.
2. Gráfico de Linha:
  - Exibe tendências ao longo do tempo.
  - Útil para mostrar o crescimento ou a diminuição de receitas, despesas ou investimentos ao longo de vários períodos.
3. Gráfico de Pizza:
  - Mostra a distribuição percentual de uma totalidade.
  - Útil para representar a composição das despesas orçamentárias, por exemplo.
4. Gráfico de Rosca:
  - Semelhante ao gráfico de pizza, mas com um buraco no centro.
  - Pode ser usado para mostrar a divisão de uma categoria em subcategorias.
5. Gráfico de Área:
  - Mostra a evolução de valores em relação ao tempo.
  - Útil para visualizar mudanças acumuladas ao longo do tempo, como o crescimento de investimentos.
6. Gráfico de Dispersão:
  - Representa pontos de dados em um plano cartesiano.
  - Útil para identificar correlações entre duas variáveis financeiras.

Regenerar

Envie uma mensagem

Atualize para Plus

Ariane Machado Lima



+ Nova conversa



⚡ GPT-3.5

⚙️ GPT-4 🔒

Hoje

Ajuda Financeira Subpr  


# ChatGPT

**Crie um esquema de base de dados**  
para uma loja online de mercadorias

**Explique supercondutores**  
como se eu tivesse cinco anos de idade

**Crie um plano de treino**  
para treino de resistência

**Ajude-me a escolher**  
um presente de aniversário para a minha mãe que gos...

Envie uma mensagem 

Atualize para Plus

A Ariane Machado Lima ...



+ Nova conversa

Default (GPT-3.5)


- Hoje
- Tipos de Gráficos
- Ajuda Financeira Subprefeitur



Me fale sobre gráficos que eu posso gerar



Claro, vou listar alguns tipos de gráficos que você pode gerar para visualizar e representar dados de maneira eficaz. A escolha do tipo de gráfico depende dos dados que você deseja comunicar e das informações que deseja destacar. Aqui estão alguns exemplos:



- Gráfico de Barras (Bar Chart):**
  - Usado para comparar categorias ou valores entre diferentes grupos.
  - Pode ser de barras verticais ou horizontais.
- Gráfico de Linhas (Line Chart):**
  - Ideal para mostrar tendências ao longo do tempo.
  - Útil para representar dados contínuos, como séries temporais.
- Gráfico de Pizza (Pie Chart):**
  - Mostra a composição de um todo, destacando a proporção de cada parte.
- Gráfico de Dispersão (Scatter Plot):**
  - Utilizado para representar relações entre duas variáveis.
  - Pontos no gráfico indicam a posição dos dados em um plano cartesiano.
- Histograma:**
  - Mostra a distribuição de dados em intervalos (bins).
  - Útil para visualizar a frequência de ocorrência de valores em um conjunto de dados.
- Gráfico de Barra Empilhada (Stacked Bar Chart):**
  - Similar ao gráfico de barras, mas empilha as barras para mostrar a composição de cada barra em relação ao total.
- Gráfico de Área (Area Chart):**
  - Representa a tendência de dados ao longo do tempo, preenchendo a área abaixo

Regenerar

Atualize para Plus

Ariane Machado Lima

Envie uma mensagem

+ Nova conversa

Hoje  
Tipos de Gráficos  
Ajuda Financeira Subpr



Eu tenho uma planilha Excel que possui várias colunas, dentre elas "investimento em educação" e "investimento em segurança", e cada linha refere-se a um mês. Como eu crio no Excel um gráfico de Linhas contendo linhas para essas duas colunas ao longo dos meses?



Para criar um gráfico de linhas no Excel com duas séries de dados, no caso "investimento em educação" e "investimento em segurança", ao longo dos meses, siga os passos abaixo:



1. Abra sua planilha do Excel que contém os dados.
2. Selecione as células que contêm os dados das colunas "investimento em educação" e "investimento em segurança" juntamente com a coluna de datas (meses). Certifique-se de incluir os rótulos das colunas. Por exemplo, se seus dados começam na célula A1 e terminam na célula C13, selecione esse intervalo.
3. Acesse a guia "Inserir" na faixa de opções.
4. Clique na opção "Gráfico de Linhas" (ou "Gráfico de Linhas com Marcadores", dependendo da versão do Excel). Isso abrirá um menu suspenso com várias opções de gráfico de linhas.
5. Escolha o tipo de gráfico de linhas desejado. Para este caso, você pode escolher "Linhas com Marcadores" para exibir pontos nos meses.
6. Um gráfico de linhas será criado na planilha e aparecerá junto aos dados selecionados.
7. No gráfico, você verá a série de dados para "investimento em educação" e "investimento em segurança" ao longo dos meses.
8. Personalize seu gráfico conforme necessário, como adicionando rótulos de eixo, título, legenda etc. Para fazer isso, clique com o botão direito do mouse em elementos do gráfico e escolha as opções de formatação.
9. Se desejar, você pode formatar as séries de dados, como escolher cores diferentes para cada série ou adicionar rótulos de dados.
10. Você pode redimensionar o gráfico e movê-lo para a posição desejada na planilha.

Lembrando que a forma exata de realizar essas etapas pode variar dependendo da versão do Excel que você está usando, mas a ideia geral é a mesma. Certifique-se de selecionar os

Regenerar

Envie uma mensagem

Atualize para Plus

Ariane Machado Lima

# Mas ele também erra... (alucinações)



Eu consigo gerar frases com um modelo de língua "bag of words"?



Sim, você pode gerar frases usando um modelo de "bag of words" (saco de palavras), embora essas frases sejam geralmente mais simples do que as geradas por modelos de



mas como é feita a escolha das palavras? Porque se fosse simplesmente escolher pelas palavras mais prováveis (sem contexto das palavras no entorno) a frase não faria sentido...



Você está correto em observar que, se você simplesmente escolher as palavras mais prováveis independentemente do contexto, a frase pode não fazer sentido. Em um modelo de "bag of words", a escolha de palavras geralmente é baseada em probabilidades, mas essas probabilidades são condicionadas ao contexto no qual as palavras aparecem.

O contexto pode ser definido de várias maneiras. Uma abordagem simples é usar um

# Mas ele também erra... (alucinações)



Mas daí você usou n-gramas... É possível gerar frases apenas com bag of words, sem o uso de n-gramas?



Peço desculpas pela confusão em minha resposta anterior. Na verdade, a geração de frases usando estritamente um modelo de "bag of words" sem considerar n-gramas ou algum tipo de contexto local não produzirá frases que façam sentido. Um modelo de "bag of words" é

.  
.  
.

Conversa completa em <https://chat.openai.com/share/6c190979-1524-4655-bd6a-2e4acc9e4337>

# Mas ele também erra... (alucinações)

- Precisa desconfiar, testar, corrigi-lo