

Extração de características

- Alternativa 3:
 - Utilizar algoritmo de aprendizado para extrair boas características automaticamente
 - Ex.: Algoritmo de aprendizado para redes neurais profundas
 - Necessário
 - Experiência em algoritmos de aprendizado que façam extração de características
 - Aspectos negativos
 - Computacionalmente custosa e precisa de muitos exemplos

© André de Carvalho - ICMC/USP

7

RNs profundas (RNP)

- Redes com 2 camadas e poucas unidades escondidas ordenam N números de N bits
 - Impossível fazer com circuito Booleano de 2 camadas
 - Precisa de muito mais camadas
 - Neurônios realizam operações de limiar de sinal
- Neurônios naturais são lentos
 - #disparos < 100 vezes por segundo
 - Para resolvermos problema em 0.1s
 - Podemos ter uma sequência de no máximo 10 disparos
 - Rede natural com 10 camadas faz o que fazemos em 0.1s

© André de Carvalho - ICMC/USP

10

RNs profundas (RNP)

- Redes neurais MLP em geral têm 1 camada intermediária
 - Redes neurais rasas (shallow)
 - Poucas camadas dificulta induzir uma função que represente bem os dados de treinamento
- Muitas camadas + *backpropagation* levam a soluções pobres
 - Problemas de atribuição de erro e lentidão
 - Piorados quando existe uma pequena quantidade de exemplos de treinamento

© André de Carvalho - ICMC/USP

8

O que podemos fazer em 0.1s

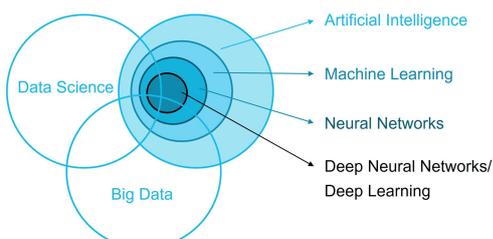
- Reconhecer uma face
- Reconhecer emoção
- Entender uma fala
- Teoricamente, RNPs podem fazer o que seres humanos fazem, em menos tempo
 - Basta encontrar valores corretos para seus pesos



© André de Carvalho - ICMC/USP

11

Diagrama de Venn



<https://www.fokus.fraunhofer.de/en/fame/workingareas/ai>

© André de Carvalho - ICMC/USP

9

Redes profundas

- Arquitetura com várias camadas
 - Mais de uma camada intermediária
 - Camadas podem ter propósitos diferentes
- Aprendizado profundo
 - Algoritmo de treinamento para treinar redes profundas
- Não muda muito em relação às redes MLP e ao seu treinamento

© André de Carvalho - ICMC/USP

12

RNs profundas

- Família de técnicas
 - Características são extraídas hierarquicamente durante o aprendizado
 - Não supervisionado
 - Pode usar dados não rotulados
 - Semi-supervisionado
 - Complexidade das características aumenta ao passar para a camada seguinte

© André de Carvalho - ICMC/USP

13

Primeiras redes profundas

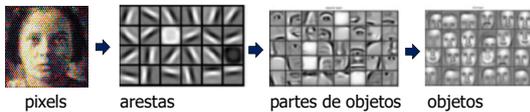
- Neognitron, 1980
- Linsker rede neural com conexões laterais, 1986
- MLP com várias camadas, 1989
- Neural history compressor, 1983
- SOFT-GSN, 1984

© André de Carvalho - ICMC/USP

16

Extração de características

- Inicialmente características simples
- Nível crescente de abstração
 - Cada camada faz uma transformação não linear das características recebidas



© André de Carvalho - ICMC/USP

14

Principais RNs profundas

- Redes neurais profundas (RNP)
- Redes autocodificadoras empilhadas (RAE)
- Redes neurais convolucionais (RNC)
- Redes credais profundas (RCP)

© André de Carvalho - ICMC/USP

17

Aspectos positivos das RNPs

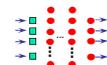
- Biologicamente plausíveis
- Para dados com n atributos preditivos
 - Número de neurônios necessários em uma rede rasa cresce exponencialmente com n
 - Em uma rede profunda, esse número cresce no máximo linearmente com n
 - Redes mais profundas podem usar menos pesos e parâmetros
 - Ex.: paridade

© André de Carvalho - ICMC/USP

15

Redes neurais profundas

- Redes com mais de uma camada intermediária
 - Em geral, completamente interconectadas
- Geralmente, as camadas intermediárias (ou parte delas) são pré-treinadas
 - Depois, utilizam *backpropagation* nas camadas finais
 - Ou em toda a rede



© André de Carvalho - ICMC/USP

18

Redes autocodificadoras

- Uma das razões para o ressurgimento do interesse em RNAs
 - Rede MLP em que:
 - Número de neurônios da camada de saída = número de entradas
 - Uma camada intermediária com muito menos neurônios que a camada de saída
 - Treinamento ensina a rede a responder com um vetor de saída igual ao vetor de entrada
 - Criadas na década de 1980

© André de Carvalho - ICMC/USP

19

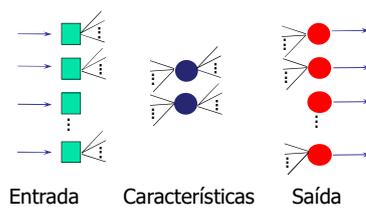
Rede autocodificadora empilhada

- Empilha autodecodificadores esparsos
 - Camada escondida do primeiro autodecodificador, se torna entrada e saída do segundo
 - Camada escondida do segundo, se torna entrada e saída do terceiro ...
 - Cada camada intermediária aprende uma representação mais sofisticada da entrada
 - E da camada intermediária anterior

© André de Carvalho - ICMC/USP

22

Rede autocodificadora

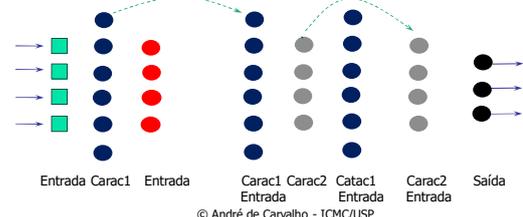


© André de Carvalho - ICMC/USP

20

Rede autocodificadora empilhada

- Treina autodecodificadores sequencialmente
 - Abordagem gulosa de treinamento
 - Altera camada de entrada e de saída a cada vez



© André de Carvalho - ICMC/USP

23

Redes autocodificadoras esparsas

- Cada ajuste dos pesos ignora a maioria dos neurônios da camada intermediária
 - Aprendizado de torna bem mais fácil
- Mais adiante, foi proposto o uso de várias camadas codificadoras
 - Redes autocodificadoras empilhadas

© André de Carvalho - ICMC/USP

21

Rede autocodificadora empilhada

- Última camada da (camada de saída)
 - Classificador softmax
 - Generalização da função sigmoid logística
 - Transforma k valores reais de um vetor em k valores $\in [0,0,1.0]$, com soma = 1
 - Treinamento
 - Indução de classificador
 - Treina última camada (ou toda a rede) com *backpropagation*

© André de Carvalho - ICMC/USP

24

RNs convolucionais

- ConvNets ou CNN
- Originalmente propostas para visão computacional
 - Procuram padrões visuais utilizando os pixels das imagens
 - Robustas a distorções e transformações geométricas
- Semelhante a rede *neocognitron*, proposta na década de 80

© André de Carvalho - ICMC/USP

25

Redes credais profundas

- Modelos probabilísticos
- Treinamento guloso camada a camada
 - Primeiras camadas recebem conexão top down da camada seguinte
 - Cada camada é uma Máquina de Boltzman restrita
 - Duas últimas camadas têm conexões bidirecionadas
 - Com pesos simétricos entre elas

© André de Carvalho - ICMC/USP

28

RNs convolucionais

- Utilizam camadas para convolução de uma imagem
 - Camadas de convolução aplicam transformações a pixels de uma imagem de entrada
- Compostas por dois estágios
 - Sequência de pares de camadas
 - Camada convolucional
 - Extrai mapas de características de uma imagem usando filtros
 - Camada de amostragem (pooling)
 - Mantém apenas as informações mais relevantes dos mapas
 - Rede MLP convencional

© André de Carvalho - ICMC/USP

26

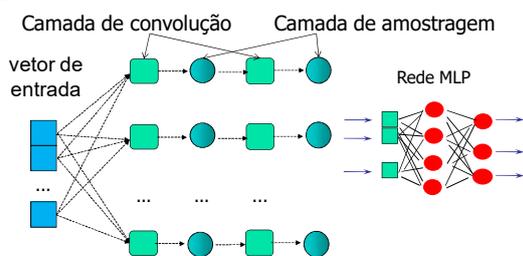
Conclusão

- Introdução
- Extração de características
- Redes profundas
- Aprendizado profundo
- Redes convolucionais
- Redes autodecodificadoras

© André de Carvalho - ICMC/USP

29

RNs convolucionais



© André de Carvalho - ICMC/USP

27

Perguntas



© André de Carvalho - ICMC/USP

30