
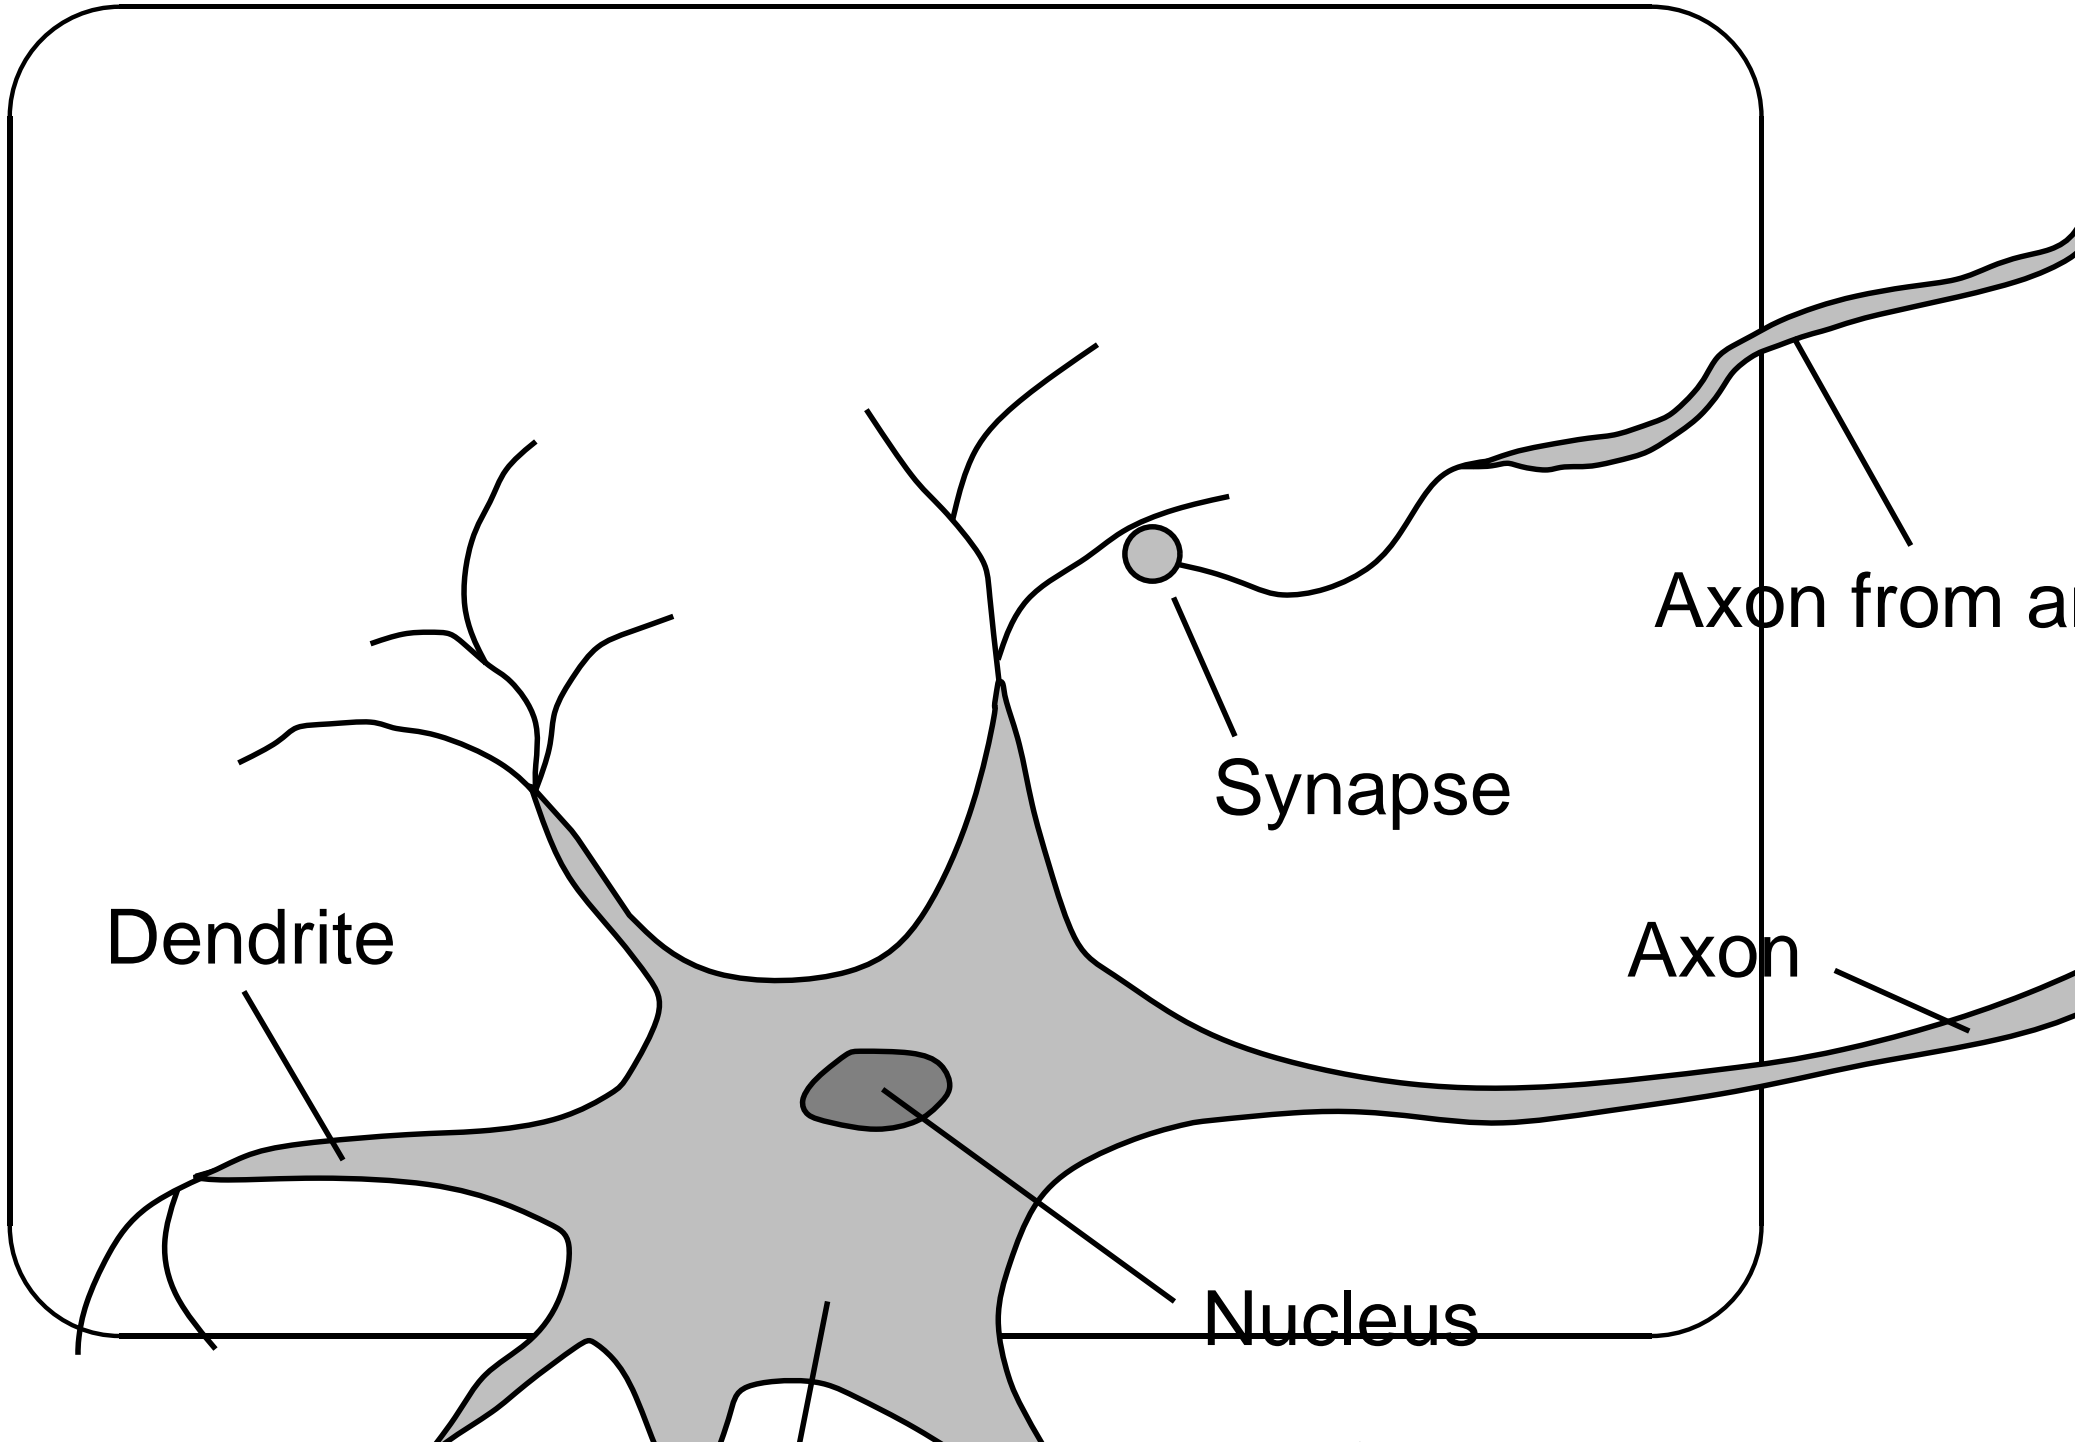


## Cap. 19, Russell: Aprendendo em Redes Neurais e Redes de Crenças

- Do ponto de vista computacional: métodos para representar funções usando redes de elementos aritméticos simples, e aprender tais representações através de exemplos.
- Do ponto de vista biológico: Modelo matemático para a operação do cérebro.
- **Neurônios:** Elementos aritméticos simples.
- **Redes Neurais:** conj de neurônios interligados.






	Computer	
Computational units	1 CPU, $10^5$ gates	
Storage units	$10^9$ bits RAM, $10^{10}$ bits disk	
Cycle time	$10^{-8}$ sec	
Bandwidth	$10^9$ bits/sec	
Neuron updates/sec	$10^5$	

## Cap. 19: Aprendendo em Redes Neurais e Redes de Crenças


- Args a favor de redes neuronais:
  - Esperança de que um dispositivo possa ser construído de forma a combinar o paralelismo inerente do cérebro com trocas rápidas de contexto.
  - Redes neuronais podem prover um modelo de paralelismo massivo em contraste com paralelização de algoritmos tradicionais.
  - **Degradação gradual:** se alguma coisa dá errada, o desempenho decresce gradualmente.
  - Projetadas para serem treinadas utilizando algoritmos de aprendizado indutivo.

## Redes Neurais


- Para construir uma rede: número de unidades, tipos de unidades, formato das conexões.
- Próximo passo: inicializar os pesos da rede, e treinar os pesos usando um algoritmo de aprendizado aplicado a um conj de treinamento para a determinada tarefa implementada pela rede.
- A operação de unidades individuais pode ser comparada com portas lógicas (McCulloch and Pitts).




**AND**





**OR**












**(a) Step function**



**(b) Sign function**

## Estruturas de Redes Neurais

- **feed-forward**: não há ciclos, grafo direcionado (DAG), links unidirecionais.
- **recorrente**: links podem formar topologias arbitrárias.
- Normalmente, redes feed-forward organizadas em camadas. Não há links entre nós da mesma camada, e links de uma camada para outra são unidirecionais.
- Computação pode prosseguir uniformemente da entrada para a saída.
- Em redes feed-forward, também não temos memória (estados internos), visto que a informação não volta para o nó.

## Exemplos de Redes Neurais Recorrentes

- **Hopfield:** conexões bidirecionais entre os nós com pesos simétricos.
- todos os nós podem ser entradas ou saídas.
- função de ativação  $g$  produz  $-1$  ou  $+1$ .
- Não encontra ótimos globais.

## Exemplos de Redes Neurais Recorrentes

- **Máquinas de Boltzmann:** também usa pesos simétricos, mas inclui unidades (escondidas) que não são entrada nem saída.
- Utilizam função de ativação estocástica, onde a prob da saída ser 1 é função dos pesos da entrada.
- Análogas ao algoritmo de “simulated annealing”, pois procura pela configuração que melhor se aproxima do conj de treinamento (tenta encontrar ótimos globais).
- Pode-se encontrar uma estrutura de rede que seja ótima através de algoritmos genéticos ou através de algoritmos do tipo “hill-climbing”.

## Perceptrons

- Exemplos mais simples de redes feed-forward com apenas 1 camada.
- O que perceptrons conseguem representar?
- Função de maioria, por exemplo, onde a saída é 1 se mais da metade das  $n$  entradas forem iguais a 1.
- $O = \text{Step}_0(\sum_j W_j I_j) = \text{Step}_0(\mathbf{WI})$
- $W_j = 1$  e threshold  $t = n/2$ .
- Mesma função de maioria representada com árvores de decisão,  $O(2^n)$  nós. Com perceptrons, 1 unidade de saída e  $n$  pesos são suficientes para representar compactamente esta função.

