

2. Redes Neurais Artificiais

Prof. Renato Tinós

Depto. de Computação e Matemática (FFCLRP/USP)

2.1. Introdução às Redes Neurais Artificiais (RNAs)

2.1.1. Motivação

2.1.2. O que são RNAs?

2.1.3. Áreas de aplicações de RNAs

2.1.1. Motivação

- **O cérebro funciona de forma diferente dos computadores convencionais**
 - Neurônios são de cinco a seis ordens de grandeza mais lentos que as portas lógicas dos micro-processadores
 - » Ordem de grandeza dos eventos
 - ❑ Em portas lógicas: nanossegundos (10^{-9} s)
 - ❑ Em neurônios: milissegundos (10^{-3} s)

2.1.1. Motivação

- **O cérebro funciona de forma diferente dos computadores convencionais**
 - Lentidão compensada por
 - » Grande número de neurônios massivamente conectados
 - ❑ Estima-se que haja 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses
 - » Extrema eficiência na operação
 - ❑ Eficiência energética do cérebro é de aproximadamente 10^{-16} J por operação por segundo, enquanto que em computadores é de cerca de 10^{-6} J

2.1.1. Motivação

	Computador Von Neumann	Sistema neural biológico
Processador	unidade básica complexa alta velocidade um ou poucos	unidade básica simples baixa velocidade grande número
Memória	separada do processador localizada não-endereçável pelo conteúdo	integrada com processador distribuída endereçável pelo conteúdo
Computação	centralizada seqüencial programas armazenados	distribuída paralela aprendizado
Confiabilidade	muito vulnerável	robusto
Adequação	manipulações num. e simbólica	problemas de percepção
Ambiente operacional	bem definido muito restrito	pouco definido não restrito

2.1.1. Motivação

- **Principais partes de um neurônio**
 - **Dendritos**
 - » Recebem informações de outros neurônios
 - » As informações fluem dos dendritos para o axônio
 - **Axônio**
 - » Transmite informação para outros neurônios
 - » Sinais viajam através dos axônios em forma de impulsos elétricos

2.1.1. Motivação


- **Principais partes de um neurônio**
 - **Corpo celular (ou Soma)**
 - » Combina (processa) informações provenientes dos dendritos
 - Disparo do axônio depende da soma dos impulsos recebidos
 - Limiar de disparo

2.1.1. Motivação

- **Ligação entre neurônios**
 - Sinapse
 - » Permite uma célula influenciar a outra
 - » Transmissão sináptica se faz por um mecanismo de natureza química
 - Através da ação de neurotransmissores


2.1.1. Motivação

- Um neurônio simplificado:



2.1.1. Motivação

- Modelo Simples de um neurônio



y : ativação (saída do neurônio)

u : ativação interna

$$y = \varphi(u) = \varphi\left(\sum_{i=1}^m x_i w_i\right)$$

2.1.2. O que são Redes Neurais Artificiais?

- **Início**

- (1943) McCulloch & Pitts

- » Desenvolvem um modelo matemático de um neurônio (nodo)
- » Combinação de vários nodos em sistemas neurais produz um elevado poder computacional
 - ❑ Nodos executam funções lógicas simples
 - ❑ Cada nodo pode executar uma função diferente
 - ❑ Qualquer função que puder ser representada por uma combinação de funções lógicas pode ser modelada por uma rede de nodos

2.1.2. O que são Redes Neurais Artificiais?

- **Sistemas inspirados em algumas propriedades simples do funcionamento do sistema nervoso**
- **Estruturas distribuídas**
 - Formadas por grande número de unidades de processamento (“neurônios”) interligadas por um grande número de conexões (“sinapses”)

2.1.2. O que são Redes Neurais Artificiais?

- **Definição de rede neural (Haykin, 2001)**
 - “Uma rede neural é um processador maciçamente e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:
 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

2.1.2. O que são Redes Neurais Artificiais?

- **Algumas definições**

- **Neurônio (artificial)**

- » unidade básica de processamento

- **Peso sináptico**

- » conexão entre neurônios

- **Algoritmo de aprendizagem**

- » modificação dos parâmetros da RNA (Ex.: pesos sinápticos) de uma forma ordenada para alcançar um objetivo dado

- **Arquitetura da RNA**

- » disposição espacial dos neurônios e pesos sinápticos (estrutura)

2.1.3. Áreas de Aplicações de RNAs

- **Aprendizado de Máquina**
 - Área da Inteligência Artificial
 - Objetivos
 - » Desenvolvimento de ferramentas computacionais capazes de tomar decisões e resolver problemas baseadas em experiências acumuladas
 - » Desenvolvimento de técnicas computacionais capazes de **adquirir e armazenar conhecimento de forma automática**

2.1.3. Áreas de Aplicações de RNAs

- **Componentes fundamentais de um sistema de AM**
 - **Representação**
 - » Modo de representar o conhecimento adquirido
 - **Raciocínio**
 - » Habilidade em resolver problemas
 - **Aprendizado**
 - » Utilização de informação para aperfeiçoar o conhecimento adquirido


2.1.3. Áreas de Aplicações de RNAs

- **Categorias de sistemas de aprendizado**
 - **Simbólico**
 - » Desenvolve representações simbólicas do conhecimento
 - ❑ As representações, geralmente, podem ser facilmente interpretadas por seres-humanos
 - **Não-simbólico**
 - » Desenvolve representações próprias do conhecimento
 - ❑ As representações, geralmente, não são facilmente interpretadas por seres-humanos
 - ❑ Entre as técnicas não-simbólicas, destaca-se as técnicas connexionistas
 - ❑ Redes Neurais Artificiais

2.1.3. Áreas de Aplicações de RNAs

- Basicamente, RNAs são aplicadas em tarefas que envolvem a **aproximação de funções**

- $y = f(x)$
- Mapeamento entrada-saída



- No aprendizado supervisionado, a função $f(.)$ é estimada através de um conjunto de entradas e saídas
 - » Conjunto de treinamento

2.1.3. Áreas de Aplicações de RNAs

- Dados pares $(x, f(x))$, inferir $f(\cdot)$

Ex.:

x	$f(x)$
1	1
2	4
3	9
4	16
5	?

Observação:

Dada uma amostra finita, é muito difícil determinar a verdadeira função $f(\cdot)$

Abordagem:

- Encontre uma **hipótese (modelo)** através dos exemplos de treinamento
- Valide esta hipótese através de exemplos de teste
- Assuma que a hipótese se repita para exemplos futuros

2.1.3. Áreas de Aplicações de RNAs

- **Em geral, um conjunto de exemplos é dividido em dois subconjuntos disjuntos:**
 - **conjunto de treinamento** que é usado para o aprendizado do conceito e o
 - **conjunto de teste** que é usado para medir o grau de efetividade do conceito aprendido
- **Os subconjuntos são disjuntos para assegurar que as medidas obtidas utilizando o conjunto de teste sejam de um conjunto diferente do usado para realizar o aprendizado, tornando a medida estatisticamente válida**

2.1.3. Áreas de Aplicações de RNAs

- **Aproximação de funções**

- Saídas assumem valores discretos

- » Reconhecimento de padrões

- Exemplos:

- Classificação

- Clusterização

- Saídas assumem valores contínuos

- » Regressão

- Exemplos:

- Mapeamento estático de entrada saída de funções com valores contínuos

- Associação de Padrões (memória associativa)

- Previsão de séries temporais

- Filtragem

2.1.3. Áreas de Aplicações de RNAs

- **Classificação**

- Rede classifica novas entradas em uma entre várias categorias discretas
- Exemplo
 - » Reconhecimento de caracteres



2.1.3. Áreas de Aplicações de RNAs



Greater earless lizard (*Cophosaurus texanus*), identified by
B kimmel 13:26, 26 October 2005 (UTC)
Image taken in Big Bend NP, TX, USA by User:Dschwen

espécime	massa em gramas	comprimento da passagem de ar do focinho em milímetros	dimensão do membro posterior em milímetros	sexo
1	5.526	59	113.5	F
2	10.401	75	142	M
3	9.213	69	124	F
4	8.953	67.5	125	F
5	7.063	62	129.5	M
6	6.61	62	123	F
7	11.273	74	140	M
8	2.447	47	97	F
9	15.493	86.5	162	M
10	9.004	69	126.5	F
11	8.199	70.5	136	M
12	6.601	64.5	116	F
13	7.622	67.5	135	M
14	10.067	73	136.5	M
15	10.091	73	135.5	M
16	10.888	77	139	F
17	7.61	61.5	118	M
18	7.733	66.5	133.5	M
19	12.015	79.5	150	M
20	10.049	74	137	M
21	5.149	59.5	116	F
22	9.158	68	123	F
23	12.132	75	141	M
24	6.978	66.5	117	F
25	6.89	63	117	?

Bank Marketing Data Set

Download: [Data Folder](#), [Data Set Description](#)

Abstract: The data is related with direct marketing campaigns (phone calls) of a Portuguese banking institution. The classification goal is to predict if the client will subscribe a term deposit (variable y).

Data Set Characteristics:	Multivariate	Number of Instances:	45211	Area:	Business
Attribute Characteristics:	Real	Number of Attributes:	17	Date Donated	2012-02-14
Associated Tasks:	Classification	Missing Values?	N/A	Number of Web Hits:	956293

Source:

Moro et al., 2014] S. Moro, P. Cortez and P. Rita. A Data-Driven Approach to Predict the Success of Bank Telemarketing. Decision Support Systems, Elsevier, 62:22-31, June 2014

Attribute Information:

Input variables:

bank client data:

- 1 - age (numeric)
- 2 - job : type of job (categorical: 'admin.', 'blue-collar', 'entrepreneur', 'housemaid', 'management', 'retired', 'self-employed', 'services', 'student', 'technician', 'unemployed', 'unknown')
- 3 - marital : marital status (categorical: 'divorced', 'married', 'single', 'unknown'; note: 'divorced' means divorced or widowed)
- 4 - education (categorical: 'basic.4y', 'basic.6y', 'basic.9y', 'high.school', 'illiterate', 'professional.course', 'university.degree', 'unknown')
- 5 - default: has credit in default? (categorical: 'no', 'yes', 'unknown')
- 6 - housing: has housing loan? (categorical: 'no', 'yes', 'unknown')
- 7 - loan: has personal loan? (categorical: 'no', 'yes', 'unknown')

related with the last contact of the current campaign:

- 8 - contact: contact communication type (categorical: 'cellular', 'telephone')
- 9 - month: last contact month of year (categorical: 'jan', 'feb', 'mar', ..., 'nov', 'dec')
- 10 - day_of_week: last contact day of the week (categorical: 'mon', 'tue', 'wed', 'thu', 'fri')
- 11 - duration: last contact duration, in seconds (numeric). Important note: this attribute highly affects the output target (e.g., if duration=0 then y='no'). Yet, the duration is not kr purposes and should be discarded if the intention is to have a realistic predictive model.

other attributes:

- 12 - campaign: number of contacts performed during this campaign and for this client (numeric, includes last contact)
- 13 - pdays: number of days that passed by after the client was last contacted from a previous campaign (numeric; 999 means client was not previously contacted)
- 14 - previous: number of contacts performed before this campaign and for this client (numeric)
- 15 - poutcome: outcome of the previous marketing campaign (categorical: 'failure', 'nonexistent', 'success')

social and economic context attributes


- 16 - emp.var.rate: employment variation rate - quarterly indicator (numeric)
- 17 - cons.price.idx: consumer price index - monthly indicator (numeric)
- 18 - cons.conf.idx: consumer confidence index - monthly indicator (numeric)
- 19 - euribor3m: euribor 3 month rate - daily indicator (numeric)
- 20 - nr.employed: number of employees - quarterly indicator (numeric)

Output variable (desired target):

- 21 - y - has the client subscribed a term deposit? (binary: 'yes', 'no')

2.1.3. Áreas de Aplicações de RNAs

- **Clusterização (ou categorização)**
 - Rede explora semelhanças entre padrões e agrupa padrões de acordo com a semelhança
 - » Aprendizado não-supervisionado
 - » Análise de dados
 - Extrai informações de um conjunto de dados
 - » Exemplos
 - Mineração de dados
 - Compressão de dados



2.1.3. Áreas de Aplicações de RNAs

- **Clusterização**


- Exemplo:

- » Dez exemplos ($n=10$)
 - » Três atributos ($m=3$):
Idade, tipo de veículo (*Esporte*, *Van*, *Caminhão*) e cor do veículo
 - » Neste caso, não há associação explícita de algum atributo com uma determinada classe


<i>Idade</i>	<i>Veículo</i>	<i>Cor</i>
20	V	preto
30	V	verde
25	C	azul
30	E	branco
40	E	azul
20	C	preto
30	V	branco
25	V	azul
40	V	Verde
20	E	azul

2.1.3. Áreas de Aplicações de RNAs

- **No Aprendizado Supervisionado, cada exemplo é rotulado segundo sua classe**




- **No Aprendizado Não Supervisionado, cada exemplo não possui classe associada**



2.1.3. Áreas de Aplicações de RNAs

- **Regressão**

- Rede associa novas entradas a saídas que assumem valores contínuos
- Para isso, deve reproduzir da melhor maneira o mapeamento entrada-saída da função $f(\cdot)$



2.1.3. Áreas de Aplicações de RNAs

- **Regressão**

- **Exemplo**

- » Dez exemplos ($n=10$)
 - » Dois atributos ($m=2$):
Idade e tipo de veículo
(*E*sporte, *V*an, *C*aminhão)
 - » Despesa indica quanto a
pessoa gastou em
manutenção
 - » Atributo dependente
(classe) é *numérico*

<i>Idade</i>	<i>Veículo</i>	<i>Despesa</i>
20	V	\$200
30	V	\$150
25	C	\$300
30	E	\$220
40	E	\$400
20	C	\$80
30	V	\$100
25	V	\$125
40	V	\$500
20	E	\$420

1.4. Áreas de Aplicações de RNAs

- **Exemplos de Software**

- Bibliotecas em diversas linguagens

- » Bibliotecas em Matlab, R
- » Theano (Phyton)
- » TensorFlow (Google Brain)

- Simuladores


- » Stuttgart Neural Network Simulator (SNNS), Emergent, Neural Lab

- Software para AM

- » Weka (Java), Scikit Learn (Phyton)

1.4. Áreas de Aplicações de RNAs

• Hardware



IBM AI Research

Hardware for AI

Much of today's computation remains tied to hardware built for spreadsheets and databases. When used for AI, it is power-hungry and inefficient. IBM is pushing the physics of AI to deliver radical improvement over the next decade, with innovation and co-development from algorithms to systems to devices.

Exploring the future of AI →

Latest news | IBM Launches Research Collaboration Center to Drive Next-Generation AI Hardware Read the blog → And

Featured Projects

AI Optimized Systems - Click Logs Benchmark




Applying co-optimized software and hardware

AI Optimized Systems




A data-centric approach to systems

Digital AI Cores



TrueNorth: Low-power inference engine



nature > nature communications > articles > article

a natureresearch journal

Search E-alert Submit Login

Download PDF

Neuromorphic computing with multi-memristive synapses

Irem Boybat, Manuel Le Gallo, S. R. Nandakumar, Timoleon Moraitis, Thomas Parnell, Tomas Tuma, Bipin Rajendran, Yusuf Leblebici, Abu Sebastian & Evangelos Eleftheriou

Nature Communications 9, Article number: 2514 (2018) | Download Citation | 9420 Accesses | 41 Citations | 134 Altmetric | Metrics >>

Abstract

Neuromorphic computing has emerged as a promising avenue towards building the next generation of intelligent computing systems. It has been proposed that memristive devices, which exhibit history-dependent conductivity modulation, could efficiently represent the synaptic weights in artificial neural networks. However, precise modulation of the device conductance over a wide dynamic range, necessary to maintain high network accuracy, is proving to be challenging. To address this, we present a multi-memristive synaptic architecture with an efficient global counter-based arbitration scheme. We focus on phase change memory devices, develop a comprehensive model and demonstrate via simulations the effectiveness of the concept for both spiking and non-spiking neural networks. Moreover, we present experimental results involving over a million phase change memory devices for unsupervised learning of temporal correlations using a spiking neural network. The work presents a significant step towards the realization of large-scale and energy-efficient neuromorphic computing systems.

Associated Content

Collection
Top 50: Physics

Sections	Figures	References
Abstract		
Introduction		
Results		
Discussion		
Methods		
References		
Acknowledgements		
Author information		
Ethics declarations		
Additional information		
Electronic supplementary material		
Rights and permissions		
About this article		
Further reading		
Comments		

<https://towardsdatascience.com/how-to-make-your-own-deep-learning-accelerator-chip-1ff69b78ece4>

- **Referências**

- **Anderson, J. A. *An introduction to neural networks*. MIT Press, 1995.**
 - » Capítulos 1 e 2
- **Haykin, S. S.. *Redes neurais: princípios e prática*. 2ª ed., Bookman, 2001.**
 - » Capítulo 1 e Seção 2.10
- **Braga, A.P.; Carvalho, A.C.P.L.F. & Ludermir, T.B.. *Redes neurais artificiais: Teoria e Aplicações*. LTC, 2000.**
 - » Capítulo 1