

# Redes Neurais Aplicadas em Simulação de Circuitos Eletrônicos

## Simulation of Electronic Circuits using Neural Networks

Márcio Mendonça\*

Juliano Monteiro Néia\*\*

Everaldo Ribeiro Brinhole\*\*\*

\* Docente do curso de Engenharia Elétrica e Telecomunicações da Universidade Norte do Paraná (UNOPAR)

e-mail: <marcio.mendonca@prof.unopar.br>

\*\* Discente do curso de Engenharia Elétrica e Telecomunicações da Universidade Norte do Paraná (UNOPAR)

e-mail: <gintam@zipmail.com.br>

\*\*\* Docente do curso de Engenharia Elétrica e Telecomunicações da Universidade Norte do Paraná (UNOPAR)

e-mail: <everaldo@unopar.br>

### Resumo

Este trabalho apresenta uma nova proposta para simulação de circuitos eletrônicos, aplicando redes neurais artificiais treinadas a partir de modelos físicos reais.

**Palavras-chave:** Simulação de circuitos, redes neurais artificiais e circuitos eletrônicos.

### Abstract

*This work presents a new proposal for simulation of electronic circuits using Artificial Neural Networks developed from real physical models.*

**Key words:** Neural Networks, circuits simulation and electronic circuits.

### Introdução

Este trabalho visa deslumbrar uma simulação em circuitos eletrônicos a partir do treinamento de uma rede neural com dados obtidos no modelo físico real do circuito eletrônico, buscando uma técnica de refinamento na simulação de circuitos. Como, por exemplo, testar o comportamento de um determinado circuito com o mesmo transistor, só que com um Beta (ganho) diferente, situação muito comum em projeto e manutenção eletrônica. A simulação de circuitos eletrônicos tem larga aplicação como um passo prévio no projeto de circuitos eletrônicos. As vantagens dos métodos tradicionais de simulação são:

- Ajustes de parâmetros iniciais a um determinado circuito.
- Tempo de simulação mais rápido do que a montagem dos circuitos.
- Identificação de problemas antes mesmo de suas ocorrências.
- Revelação da integridade e viabilidade de um determinado problema.
- Redução de custos com emprego de recursos.

A idéia da aplicação de redes neurais artificiais, na simulação dos circuitos eletrônicos como uma possível ferramenta para simulação de circuitos, não invalida a aplicação de softwares tradicionais no desenvolvimento do projeto, mas sim uma técnica de refinamento em novas situações de funcionamento. A motivação deste trabalho está na capacidade de aprendizado das redes neurais artificiais aplicadas a coleta de dados de um circuito real, para que se possa submeter o mesmo circuito em situações diferentes das condições de

funcionamento, após o treinamento da rede neural artificial. A motivação da aplicação das redes neurais artificiais neste trabalho consiste no treinamento da rede em situações reais de funcionamento, enquanto que softwares tradicionais utilizam modelos matemáticos dos componentes. A seguir são apresentadas algumas importantes características e vantagens de se utilizar redes neurais artificiais.

As redes neurais artificiais (RNA) consistem em um método de solucionar problemas relacionados a engenharia e ciências por intermédio de circuitos simples que simulam o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. Além disso, RNA são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios.

Em um sistema de rede neural, a informação pode parecer ter representação redundante, porém, o fato de que ela se encontre distribuída por todos os elementos da rede significa que, mesmo que parte da rede seja destruída, a informação contida nesta parte ainda estará presente na rede e poderá ser recuperada. Portanto, a redundância na representação de informações em uma rede neural, diferente de outros sistemas, transforma-se em uma vantagem, que torna o sistema tolerante a falhas. Os atributos de uma rede neural, tais como aprender através de exemplos, neste trabalho gerado por modelos matemáticos ou aquisição de pontos em imagens, generalizações redundantes e tolerância a falhas proporcionam fortes incentivos para a escolha de redes neurais como uma escolha apropriada para aproximação para a modelagem de sistemas biológicos.

Todo o potencial de uma rede neural pode ser enumerado nos parágrafos seguintes:

- O modelo de rede neural tem muitos neurônios conectados por pesos com capacidade de adaptação que podem ser arranjados em uma estrutura paralela, neurocomputação onde os dados são processados de forma paralela e não seqüencial como no processamento tradicional.
- Por causa desse paralelismo, a falha de alguns neurônios não causa efeitos significantes para a performance de todo o sistema, o que é chamado de tolerância a falhas.
- Uma importante característica de redes neurais reside em sua habilidade de adaptação e aprendizagem. A habilidade de adaptação e aprendizagem pelo ambiente significa que modelos de redes neurais podem lidar com dados imprecisos e situações não totalmente definidas, robustez. Isso significa que ela é imune a pequenas falhas e a rede poderá reconhecer um determinado padrão embora existam distorções em suas entradas (HAYKIN, 2000).
- Uma rede treinada de maneira razoável tem a habilidade de generalizar quando é apresentada a entradas que não estão presentes em dados já conhecidos por ela.
- Uma característica significativa de redes neurais está em sua habilidade de aproximar qualquer função contínua não linear de um grau de correção desejado. Essa habilidade das redes neurais as tem tornado útil para modelar sistemas não lineares na combinação de controladores não lineares, como circuitos eletrônicos que se utilizam de componentes com comportamento não lineares, por exemplo, o transistor bipolar como mostra a literatura.

Com o avanço em tecnologias de hardware, existem componentes com funções voltadas a sistemas com implementações voltadas para redes neurais, o que traz uma velocidade adicional à computação neural. Na próxima seção detalharemos a aplicação da rede neural como proposta de simulação de circuitos eletrônicos.

## 1 Materiais e Métodos

O tipo de rede neural utilizado e também o mais difundido e aplicado é a perceptron back propagation, treinada a partir de parâmetros intrínsecos e extrínsecos de um circuito eletrônico, demonstrado na Figura 1. O uso da rede perceptron, é uma rede do tipo de supervisionada, ou seja, treinada a partir de padrões de teste apresentados nas camadas de entradas e saídas da rede. Assim a aplicação de redes neurais consiste em duas etapas:

- Treinamento da rede: Padrões predeterminados em uma pesquisa são apresentados em suas entradas e suas respectivas respostas apresentadas nas camadas de saída da rede.
- Teste da rede: Após a primeira etapa, a rede então é testada com linhas preferencialmente diferentes das linhas de parâmetros utilizadas no treinamento.

O número de padrões de treinamento é determinado empiricamente, sendo muito importante também ser cuidadoso em se treinar a rede nas diversas situações de funcionamento do circuito. No nosso caso, foram utilizadas aproximadamente 80 linhas de treinamento com uma importante observação na corrente de coletor ( $I_c$ ) do transistor a qual serve de parâmetro para se verificar situações de saturação, condução e corte de um transistor, que, de acordo com a literatura, são as possíveis regiões de trabalho de um transistor bipolar. O número de padrões de teste são igualmente empíricos, porém na prática um número de seis padrões é bastante aplicado.

O número de camadas e neurônios na configuração da rede neural, ou seja, a topologia utilizada na rede. O número de neurônios por ser também empíricos, é sempre determinado pelo acréscimo de 10 em 10 neurônios, iniciando-se com um mínimo de 10. Apesar de existirem alguns estudos estatísticos, para se tentar determinar um número ótimo de neurônios na camada intermediária sem perder a precisão da rede, a determinação do número de neurônios intermediários ainda é bastante determinado pelo método de acréscimo de neurônios. Quanto ao número de camadas intermediárias, com apenas uma camada intermediária, a rede neural artificial pode generalizar qualquer sistema não linear.

No desenvolvimento deste trabalho, os padrões de entrada da rede neural são os parâmetros intrínsecos ao transistor, no nosso caso a corrente de base e a tensão de base emissor, e parâmetros extrínsecos como o resistor de emissor. Entretanto na camada de saída são utilizados apenas parâmetros intrínsecos de saída do transistor, a corrente de coletor ( $I_c$ ) e tensão de coletor e emissor ( $V_{ce}$ ).

Basicamente o objetivo deste trabalho é de determinar a tensão e corrente de saída de um transistor montado em um circuito básico Figura 1, a partir dos parâmetros intrínsecos e extrínsecos apresentados como padrões de entrada para a rede neural.

Uma possível extensão desta pesquisa seria treinar a rede neural com transistores de ganho diferentes (beta) e depois testar o comportamento do circuito com betas diferentes dos padrões de treinamento.

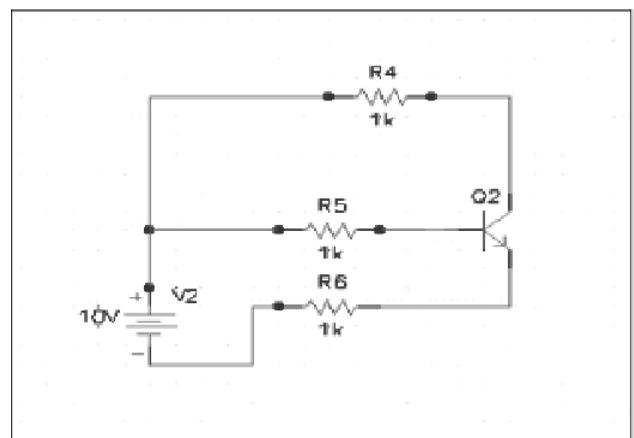
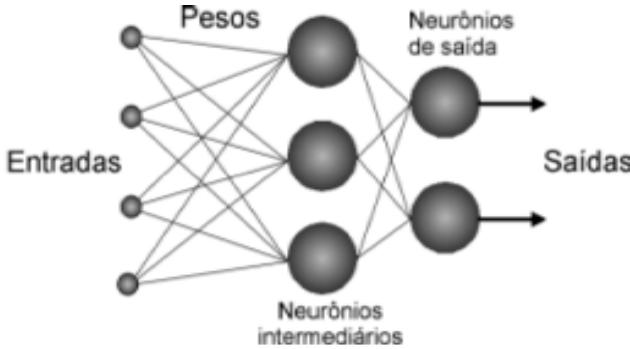


Figura 1 – Circuito eletrônico de ensaio.

É importante notar que este é um trabalho de apresentação de uma proposta de simulação de circuitos, utilizando redes neurais artificiais do tipo perceptron back propagation, e que o circuito ensaiado foi básico, mas que a proposta pode ser estendida a outros tipos de circuitos eletrônicos em diversas outras áreas de aplicação na engenharia eletrônica.

A Figura 2 mostra a topologia das redes neurais utilizadas neste trabalho.



**Figura 2** – Topologia das camadas.

Na Tabela 1, são apresentadas as linhas de teste e treinamento ensaiadas a partir do circuito apresentado na Figura 1. As linhas em vermelho não foram utilizadas no treinamento da rede, para posterior uso em teste.

Uma importante observação para a montagem do circuito deste trabalho foi o uso de um transistor bipolar NPN BC 548.

O software utilizado foi o MatLab versão 5.1 student e o hardware um AMDK6-2 500 Mhz 132 MB de memória Ram. Componentes eletrônicos discretos dos laboratórios da Unopar. Transistor bipolar BC548 NPN, resistores 1/8 W diversos e fonte de alimentação.

**2 Resultados e Discussão**

A rede neural generalizou com uma só camada intermediária, provando que teoricamente a rede pode generalizar com apenas uma camada intermediária com funções que possuem um domínio contínuo (HAYKIN, 2000).

A Tabela 2 mostra os resultados encontrados pela RNA.

De acordo com os resultados obtidos neste trabalho podemos aplicar redes neurais artificiais como uma nova ferramenta em simulação de circuitos eletrônicos, nas diversas áreas de projetos de circuitos eletrônicos.

**Referências**

BRAGA, A. de P.; LUDEMIR, T. B.; CARVALHO, A. C. P. de L. F.. *Redes neurais: teoria e aplicações.* São Paulo: Livros Técnicos e Científicos, 2001.

HAYKIN, S.. *Redes Neurais, princípios e prática.* 2 ed. São Paulo: Bookman, 2000.

JAGADEV, H. S.; BOWNE, J.; JORDAN P.. Verification and validation issues in industrial engineering models. *Computers in Industry*, n. 25, p. 331-353, 1995.

LAW, A M.; KELTON, W. D. *Simulation modeling and analysis.* 2<sup>nd</sup> ed. Singapore: McGraw-Hill, 1991. 759p. Series in industrial engineering and management science.

MENNER, W. A. *Introducion to modeling and simulation. Johns Hopkins APL Technical Digets*, v. 16, n. 1, p. 6-17, 1995.

SEDRÁ, A. S.; SMITH, D. C.. *Microeletrônica.* 4. ed. São Paulo: Makron Books do Brasil, 2000.

WINSTON, W. L. *Operations research: applicatins and algorithms.* 3<sup>th</sup> ed. Belmont, California: Wadsworth Publishing, 1994. 1353p.

**Tabela 1** – Linhas de teste e treinamento da rede.

	Rb( $\Omega$ )	Rc( $\Omega$ )	Re( $\Omega$ )	Vcc(V)	Vbe(V)	Ib(A)	Vce(V)	Ic(A)
1	0	220	47	12	0.699	0.427m	81.60m	44.4m
2	0	220	120	12	0.690	0.331m	80.50m	35.1m
3	0	220	220	12	0.681	0.248m	79.90m	27.0m
4	0	330	47	12	0.690	0.454m	62.40m	32.0m
5	0	330	120	12	0.684	0.376m	61.80m	26.9m
6	0	330	220	12	0.677	0.301m	61.30m	21.9m
7	0	560	47	12	0.680	0.482m	43.30m	19.8m
8	0	560	120	12	0.677	0.427m	43.20m	17.7m
9	0	560	220	12	0.671	0.367m	43.00m	15.3m
10	<b>0</b>	<b>1,2K</b>	<b>47</b>	<b>12</b>	<b>0.667</b>	<b>0.505m</b>	<b>25.37m</b>	<b>9.7m</b>
11	0	1,2K	120	12	0.666	0.475m	25.35m	9.1m
12	0	1,2K	220	12	0.662	0.437m	25.65m	8.5m
13	47K	220	47	12	0.667	0.144m	2.405	35.8m
14	47K	220	120	12	0.662	0.118m	2.230	29.0m
15	47K	220	220	12	0.657	94.2 $\mu$	1.980	22.7m
16	47K	330	47	12	0.681	144.4 $\mu$	161.5m	29.0m
17	47K	330	120	12	0.676	120.1 $\mu$	164.4m	25.5m
18	47K	330	220	12	0.670	96.6 $\mu$	176.8m	20.7m
19	47K	560	47	12	0.671	153.0 $\mu$	87.3m	19.6m
20	47K	560	120	12	0.668	136.0 $\mu$	87.4m	17.7m
21	47K	560	220	12	0.663	117.1 $\mu$	87.6m	14.7m
22	47K	1,2K	47	12	0.665	160.2 $\mu$	53.0m	9.6m
23	47K	1,2K	120	12	0.653	151.0 $\mu$	53.1m	8.0m
24	47K	1,2K	220	12	0.651	139.4 $\mu$	53.2m	8.5m
25	100K	220	47	12	0.638	86.2 $\mu$	6.13	21.6m
26	100K	220	120	12	0.641	76.1 $\mu$	5.55	19.1m
27	100K	220	220	12	0.637	65.4 $\mu$	4.89	16.3m
28	100K	330	47	12	0.645	86.4 $\mu$	4.027	21.4m
29	100K	330	120	12	0.644	76.3 $\mu$	3.65	18.8m
30	<b>100K</b>	<b>330</b>	<b>220</b>	<b>12</b>	<b>0.647</b>	<b>66.0 <math>\mu</math></b>	<b>3.38</b>	<b>15.8m</b>
31	100K	560	47	12	0.665	86.7 $\mu$	178.5m	18.0m
32	100K	560	120	12	0.664	77.0 $\mu$	199.3m	17.5m
33	100K	560	220	12	0.654	66.9 $\mu$	225.0m	15.2m
34	100K	1,2K	47	12	0.650	90.9 $\mu$	75.7m	9.7m
35	100K	1,2K	120	12	0.649	84.5 $\mu$	75.9m	9.2m
36	100K	1,2K	220	12	0.646	79.5 $\mu$	76.0m	8.5m
37	560K	220	47	12	0.613	19.2 $\mu$	10.87	4.5m
38	560K	220	120	12	0.611	18.7 $\mu$	10.57	4.4m
39	560K	220	220	12	0.612	18.0 $\mu$	10.22	4.1m
40	560K	330	47	12	0.612	19.2 $\mu$	10.39	4.5m
41	560K	330	120	12	0.613	18.6 $\mu$	10.13	4.4m
42	560K	330	220	12	0.613	18.0 $\mu$	9.78	4.1m
43	560K	560	47	12	0.615	19.2 $\mu$	9.37	4.5m
44	560K	560	120	12	0.614	19.1 $\mu$	9.13	4.3m
45	560K	560	220	12	0.614	18.4 $\mu$	8.84	4.1m
46	560K	1,2K	47	12	0.616	19.3 $\mu$	6.58	4.3m
47	560K	1,2K	120	12	0.617	18.7 $\mu$	6.47	4.3m
48	560K	1,2K	220	12	0.616	18.1 $\mu$	6.26	4.1m
49	680K	220	47	12	0.610	16.3 $\mu$	11.07	3.77m
50	<b>680K</b>	<b>220</b>	<b>120</b>	<b>12</b>	<b>0.610</b>	<b>13.9 <math>\mu</math></b>	<b>10.82</b>	<b>3.67m</b>
51	680K	220	220	12	0.609	15.4 $\mu$	10.51	3.55m
52	680K	330	47	12	0.610	16.2 $\mu$	10.67	3.73m
53	680K	330	120	12	0.609	15.6 $\mu$	10.43	3.65m
54	680K	330	220	12	0.610	15.4 $\mu$	10.14	3.51m
55	680K	560	47	12	0.611	16.1 $\mu$	9.8	3.73m
56	680K	560	120	12	0.611	15.9 $\mu$	9.6	3.63m
57	680K	560	220	12	0.610	15.4 $\mu$	9.32	3.53m
58	680K	1,2K	47	12	0.613	16.3 $\mu$	7.48	3.96m
59	680K	1,2K	120	12	0.612	15.9 $\mu$	7.33	3.6m
60	680K	1,2K	220	12	0.613	15.4 $\mu$	7.14	3.4m
61	<b>820K</b>	<b>220</b>	<b>47</b>	<b>12</b>	<b>0.606</b>	<b>13.4 <math>\mu</math></b>	<b>11.25</b>	<b>3.06m</b>
62	820K	220	120	12	0.606	13.1 $\mu$	11.06	2.99m
63	820K	220	220	12	0.604	12.8 $\mu$	10.78	2.91m
64	820K	330	47	12	0.608	13.4 $\mu$	10.94	3.03m
65	820K	330	120	12	0.605	13.2 $\mu$	10.74	2.99m
66	820K	330	220	12	0.607	12.8 $\mu$	10.49	2.90m
67	820K	560	47	12	0.607	13.4 $\mu$	10.23	3.03m
68	820K	560	120	12	0.607	13.1 $\mu$	10.06	2.96m
69	820K	560	220	12	0.605	12.8 $\mu$	9.81	2.88m
70	820K	1,2K	47	12	0.609	13.4 $\mu$	8.34	3.01m
71	820K	1,2K	120	12	0.608	13.2 $\mu$	8.20	2.92m
72	<b>820K</b>	<b>1,2K</b>	<b>220</b>	<b>12</b>	<b>0.607</b>	<b>12.9 <math>\mu</math></b>	<b>8.01</b>	<b>2.87m</b>
73	1M	220	47	12	0.602	11.38 $\mu$	11.39	2.58m
74	1M	220	120	12	0.601	11.1 $\mu$	11.22	2.55m
75	1M	220	220	12	0.601	10.9 $\mu$	10.98	2.48m
76	1M	330	47	12	0.601	11.3 $\mu$	11.11	2.58m
77	1M	330	120	12	0.602	11.2 $\mu$	10.96	2.53m
78	1M	330	220	12	0.601	10.9 $\mu$	10.73	2.47m
79	1M	560	47	12	0.603	11.3 $\mu$	10.53	2.56m
80	1M	560	120	12	0.602	11.2 $\mu$	10.37	2.52m
81	<b>1M</b>	<b>560</b>	<b>220</b>	<b>12</b>	<b>0.601</b>	<b>10.9 <math>\mu</math></b>	<b>10.16</b>	<b>2.47m</b>
82	1M	1,2K	47	12	0.602	11.3 $\mu$	8.91	2.55m
83	1M	1,2K	120	12	0.602	11.2 $\mu$	8.79	2.5m
84	1M	1,2K	220	12	0.602	10.9 $\mu$	8.62	2.44m

**Tabela 2** – Resultados RNA x Dados Circuito.

RNA		Dados Reais	
Ic(A)	Vce(V)	Ic(A)	Vce(V)
1,98m	10,06	2.47m	10.16
2,5m	9,06	2.87m	8.01
2,73m	10,26	3.06m	11,25
3,06m	10,43	3,67m	10,82
18m	2,47	15,8m	3,38
9,1m	27,87	9,7m	25,37