


**Universidade Federal de Uberlândia**  
**Faculdade de Engenharia Elétrica**  
**Pós-Graduação em Engenharia Elétrica**



**Aplicação de Ferramentas de Inteligência  
Computacional para Estimação das Propriedades  
Físicas de uma Célula Solar de Silício**

**Fernando Barbosa Matos**

**Uberlândia**

**2011**

**Fernando Barbosa Matos**

**Aplicação de Ferramentas de Inteligência Computacional  
para Estimação das Propriedades Físicas de uma Célula  
Solar de Silício**

Tese de Doutorado

Universidade Federal de Uberlândia  
Programa de Pós-Graduação em Engenharia Elétrica  
Faculdade de Engenharia Elétrica

Tese submetida para a obtenção do título de Doutor

**Área de Concentração:** Eletricidade  
Rural e Fontes Alternativas de Energia

**Orientador:** PhD. José Roberto Camacho

Uberlândia

2011

Dados Internacionais de Catalogação na Publicação (CIP)  
Sistema de Bibliotecas da UFU, MG – Brasil

---

M433a  
2012

Matos, Fernando Barbosa, 1977-

Aplicação de ferramentas de inteligência computacional para  
estimação das propriedades físicas de uma célula solar de silício /  
Fernando Barbosa Matos. – 2012.

169f. : il.

Orientador: PhD. José Roberto Camacho.

Tese (doutorado) – Universidade Federal de Uberlândia,  
Programa de Pós-Graduação em Engenharia Elétrica.

Inclui bibliografia.

1. Engenharia elétrica – Teses. 2. Inteligência artificial –  
Teses. 3. Redes neurais (Computação) – Teses. 4. Geração de energia  
fotovoltaica – Teses. I. Camacho, José Roberto. II. Universidade  
Federal de Uberlândia. Programa de Pós-Graduação em Engenharia  
Elétrica. III. Título.

---

CDU: 621.3

**Fernando Barbosa Matos**

**Aplicação de Ferramentas de Inteligência Computacional  
para Estimação das Propriedades Físicas de uma Célula  
Solar de Silício**

Tese de Doutorado Aprovada pelo  
Programa de Pós-Graduação em  
Engenharia Elétrica da Universidade  
Federal de Uberlândia

Área de Concentração: Eletricidade Rural  
e Fontes Alternativas de Energia

Banca Examinadora:

---

Prof. José Roberto Camacho, Ph.D. (UFU) – Orientador

---

Prof. Adriano Moehleck, Dr. (PUCRS)

---

Prof. Sebastião Camargo Guimarães Jr., Dr (UFU)

---

Prof. Keiji Yamanaka, Ph.D. (UFU)

---

Prof. Gustavo Malagoli Buiatti, Dr. (Mitsubishi Electric – Solar Photovoltaic Lab.)

## Dedicatória

*A minha esposa pela força e dedicação nos momentos mais difíceis.*

*Ao meu pai que sempre esteve em meus pensamentos.*

*A minha mãe e minhas irmãs que sempre moraram no meu coração.*

## **Agradecimentos**

*Ao meu orientador, que sempre me serviu de guia para trilhar os caminhos mais obscuros do desconhecido*

## Epígrafe

*1º - Fidelidade para com o verdadeiro caminho da razão  
(Ginchin Funakoshi)*

MATOS, Fernando Barbosa. Aplicação de Ferramentas de Inteligência Computacional para Estimação das Propriedades Físicas da Célula Solar de Silício. 2011 169f. Tese para defesa de doutorado. Universidade Federal de Uberlândia – MG.

## Resumo

O desenvolvimento de modelos computacionais que possam traduzir o comportamento de células fotovoltaicas é de grande importância na compreensão desse tipo de dispositivo. Um novo modelo é proposto para determinar os tipos de dopantes utilizados no processo de fabricação, com a estimativa das suas respectivas concentrações. A utilização de técnicas auxiliadas por estratégias baseadas em Inteligência Computacional permitiu a criação de uma nova forma de simular e obter resultados, no que se refere ao processamento do modelo matemático de células fotovoltaicas. Essa nova técnica não só é capaz de obter os tipos de dopantes e suas concentrações, mas também minimizar a quantidade de informação requerida em termos de quantidade de variáveis necessárias para determinar as características comportamentais da célula solar sob os parâmetros de tensão, corrente e potência. A validade da técnica é tratada na fundamentação teórica e verificada a partir dos exemplos utilizados durante os testes sobre os modelos dos softwares PMCCF e PC-1D.

Palavras Chaves: célula solar, modelagem computacional, inteligência computacional, redes neurais artificiais, algoritmos genéticos.



MATOS, Fernando Barbosa. Application of Computational Intelligence Tools for Estimation of Physical Properties of Silicon Solar Cell. 2011 169f. Doctorate Degree Thesis. Universidade Federal de Uberlândia – MG. Brazil.

## Abstract

The development of computational models that can simulate the behavior of photovoltaic cells is of great importance in understanding this type of device. A new model is proposed to determine the types of dopants used in the manufacturing process, with the estimation of their concentrations. The use of techniques aided by computational intelligence based strategies allowed the creation of a new way to simulate and achieve results, regarding to the processing of mathematical model for photovoltaic cells. This new technique is not only able to get the types of dopants and their concentrations, but also minimize the amount of information required in term of number of variables needed to determine the behavioral characteristics of the solar cell under the parameters of voltage, current and power. The validity of the technique is treated in the theoretical and observed from the examples used during the tests applied software models PMCCF and PC-1D.

Keywords: solar cell, computer modeling, computational intelligence, neural networks, genetic algorithms.

## Lista de Figuras

FIG. 1.1: CONCENTRAÇÃO DE CO <sub>2</sub> ENTRE OS ANOS 1840 E 2000 .....	2
FIG. 1.2: ILUSTRAÇÃO DO MODELO DETERMINÍSTICO .....	8
FIG. 1.3: TÉCNICA UTILIZANDO FERRAMENTAS DE IC. ....	9
FIG. 1.4:NOVO PADRÃO DE DETERMINAÇÃO DE I X V UTILIZANDO AS TÉCNICAS DE IC.....	10
FIG. 3.1:REPRESENTAÇÃO DE UM NEURÔNIO (CÉLULA) HUMANO. ....	28
FIG. 3.2:REPRESENTAÇÃO DE UM NEURÔNIO TIPO <i>PERCEPTRON</i> .....	30
FIG. 3.3:COMPORTAMENTO ESPERADO PARA A EVOLUÇÃO DO ERRO PELO GRADIENTE DESCENDENTE PARA OS PESOS $w_0$ e $w_1$ . ....	37
FIG. 3.4:ESQUEMA ELÉTRICO DA CÉLULA SOLAR PARA A APROXIMAÇÃO DO MODELO DE UM DIODO .....	40
FIG. 3.5:CROMOSSOMO COM CODIFICAÇÃO DE GENE UTILIZANDO A CODIFICAÇÃO BINÁRIA .....	46
FIG. 3.6:CROMOSSOMO COM CODIFICAÇÃO DE GENE POR STRING SIMPLES (A) E POR STRING COMPOSTA (B).....	46
FIG. 3.7:CROMOSSOMO COM CODIFICAÇÃO DE GENE POR VALOR REAL .....	47
FIG. 5.1:GRÁFICO DO PROCESSAMENTO DO ERRO MÉDIO QUADRÁTICO PARA A RNA. ....	75
FIG. 5.2:REPRESENTAÇÃO DO CROMOSSOMO MANIPULADO PELO AG, DE ACORDO COM O POSICIONAMENTO DO SEU CAMPO DE REFERÊNCIA: (A) IRRADIAÇÃO SOLAR, (B) TEMPERATURA, (C) ÁREA, (D) TIPO DE DOPANTE N, CONCENTRAÇÕES: [(E) DOPANTE N, (F) GRANDEZA], (G) TIPO DE DOPANTE P, CONCENTRAÇÕES: [(H) DOPANTE P, (I) GRANDEZA], (J) IPMP, (K) VPMP, (L) VOC, (M) ISC. ....	77
FIG. 5.3: LEITURA PARA UMA IRRADIAÇÃO SOLAR DE 1000 W/M <sup>2</sup> E 25 °C PARA A CURVA I-V. MÉDIA ENCONTRADA PELO SHG, CURVA DE CONTROLE DO MODELO PMCCF E A CURVA ENCONTRADA PELO SHG DO EXEMPLO 1 DA TABELA 5.1. ....	82
FIG. 5.4: LEITURA PARA UMA IRRADIAÇÃO SOLAR DE 1000 W/M <sup>2</sup> E 25 °C PARA A CURVA P-V. MÉDIA ENCONTRADA PELO SHG, CURVA DE CONTROLE DO MODELO PMCCF E A CURVA ENCONTRADA PELO SHG DO EXEMPLO 1 DA TABELA 5.1. ....	83
FIG. 5.5: LEITURA PARA UMA IRRADIAÇÃO DE 1000 W/M <sup>2</sup> E -10 °C PARA A CURVA I-V, MÉDIA ENCONTRADA PELO SHG, CURVA DE CONTROLE DO MODELO PMCCF E A CURVA ENCONTRADA PELO SHG DO EXEMPLO 6 DA TABELA 5.1. ....	84
FIG. 5.6: LEITURA PARA UMA IRRADIAÇÃO SOLAR DE 1000 W/M <sup>2</sup> E -10 °C PARA A CURVA DE POTÊNCIA, MÉDIA ENCONTRADA PELO SHG, CURVA DE CONTROLE DO MODELO PMCCF E A CURVA ENCONTRADA PELO SHG DO EXEMPLO 6 DA TABELA 5.1. ....	84

FIG. 5.7: LEITURA PARA UMA IRRADIAÇÃO SOLAR DE $1000 \text{ W/M}^2$ DA CURVA I-V. COMPARATIVO DAS CURVAS DE CONTROLE DO MODELO PMCCF E MÉDIA ENCONTRADA PELO SHG PARA AS TEMPERATURAS DE 25 E $60^\circ\text{C}$ .....	86
FIG. 5.8: LEITURA PARA UMA IRRADIAÇÃO SOLAR DE $1000 \text{ W/M}^2$ DA CURVA DE POTÊNCIA. COMPARATIVO DAS CURVAS DE CONTROLE DO MODELO PMCCF E MÉDIA ENCONTRADA PELO SHG PARA AS TEMPERATURAS DE 25 E $60^\circ\text{C}$ .....	86
FIG. 5.9: LEITURA PARA A TEMPERATURA DE $25^\circ\text{C}$ DA CURVA I-V. COMPARATIVO DAS CURVAS DE CONTROLE DO MODELO PMCCF E MÉDIA ENCONTRADA PELO SHG PARA IRRADIÂNCIA DE $300 \text{ W.M}^{-2}$ E $1000 \text{ W.M}^{-2}$ .....	87
FIG. 5.10: LEITURA PARA A TEMPERATURA DE $25^\circ\text{C}$ DA CURVA POTÊNCIA. COMPARATIVO DAS CURVAS DE CONTROLE DO MODELO PMCCF E MÉDIA ENCONTRADA PELO SHG PARA IRRADIÂNCIA DE $300 \text{ W.M}^{-2}$ E $1000 \text{ W.M}^{-2}$ .....	87
FIG. 5.11: EXEMPLO DE UMA CURVA I-V UTILIZADA COMO ENTRADA DE DADOS PARA A RNA. ....	89
FIG. 5.12:ERRO MÉDIO QUADRÁTICO PARA AS PRINCIPAIS CARACTERÍSTICAS DO SOFTWARE PC-1D. ....	89
FIG. 5.13:GRÁFICO DO ERRO MÉDIO QUADRÁTICO PARA A ANÁLISE DA DENSIDADE DE CORRENTE A PARTIR DOS ELÉTRONS. ....	91
FIG. 5.14:COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO AOS ELÉTRONS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 1. ....	91
FIG. 5.15: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO AOS ELÉTRONS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 2. ....	92
FIG. 5.16: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO AOS ELÉTRONS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 3. ....	92
FIG. 5.17:GRÁFICO DO ERRO MÉDIO QUADRÁTICO PARA A ANÁLISE DA DENSIDADE DE CORRENTE GERADA PELAS LACUNAS. ....	93
FIG. 5.18:COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO A INFLUÊNCIA DAS LACUNAS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 1. ....	94
FIG. 5.19: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO A INFLUÊNCIA DAS LACUNAS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 2. ....	94
FIG. 5.20: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE DEVIDO A INFLUÊNCIA DAS LACUNAS DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 3. ....	95
FIG. 5.21:GRÁFICO DO ERRO MÉDIO QUADRÁTICO PARA A ANÁLISE DA DENSIDADE DE CORRENTE GERADA PELAS LACUNAS. ....	96
FIG. 5.22:COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE TOTAL DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 1. ....	96

FIG. 5.23: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE TOTAL DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 2. ....	97
FIG. 5.24: COMPARAÇÃO DA CURVA DA DENSIDADE DE CORRENTE TOTAL DE ACORDO COM A PROFUNDIDADE DA CÉLULA SOLAR. EXEMPLO – 3. ....	97
FIG. 5.25: REPRESENTAÇÃO DO ESQUEMA DE FUNCIONAMENTO DO SHG. ....	98
FIG. 5.26: ANÁLISE DA CURVA DE DENSIDADE DE CORRENTE DO MODELO PC-1D. ....	99
 FIG. A.1: MODELOS DE RNA –(A) RNA’S ACÍCLICAS, (A1) PERCEPTRON DE CAMADA SIMPLES, (A2) PERCEPTRON DE MULTIPLAS CAMADAS, (B) RNA’S CÍCLICAS, (B1) RNA COMPETITIVA, (B2) RNA SOM (KOHONEN), (B3) MODELO ART, (B4) RNA HOPFIELD. ....	126
FIG. A.2: GRÁFICOS DA FUNÇÃO DE ATIVAÇÃO G(NET). (A) LINEAR, (B) RAMPA, (C) SALTO, (D) SIGMÓIDE E (E) TANGENTE HIPERBÓLICA. ....	128
FIG. A.3: EXEMPLO DE CRUZAMENTO DE CROMOSSOMO DE UM PONTO UTILIZANDO CODIFICAÇÃO BINÁRIA. ....	129
FIG. A.4: EXEMPLO DE CRUZAMENTO MULTIPONTO UTILIZANDO CODIFICAÇÃO BINÁRIA DE CROMOSSOMO . ....	129
FIG. A.5: EXEMPLO DE CRUZAMENTO UTILIZANDO MÁSCARA COM CODIFICAÇÃO BINÁRIA DE CROMOSSOMO. ....	130
FIG. A.6: EXEMPLO DE MUTAÇÃO. ....	130
FIG. A.7: REPRESENTAÇÃO DA ESCOLHA PELO MÉTODO DE MONTE CARLO.....	131
FIG. B.1: COMPARATIVO DA UTILIZAÇÃO DO MOMENTUM, NO PROCESSAMENTO DA RNA . ....	139
FIG. D.1: REPRESENTAÇÃO DO CROMOSSOMO MANIPULADO AG, DE ACORDO COM O POSICIONAMENTO DO SEU CAMPO DE REFERÊNCIA: (A) ILUMINAÇÃO, (B) TEMPERATURA, (C) ÁREA, (D) TIPO DE DOPANTE N, CENTRAÇÕES: [(E) DOPANTE N, (F) GRANDEZA], (G) TIPO DE DOPANTE P, CONCENTRAÇÃO :[(H) DOPANTE P, (I) GRANDEZA], (J) IPMP, (K) VPMP, (L) VOC, (M) ISC.....	143
FIG. D.2: SORTEIO DE TRÊS CAMPOS PARA REALIZAR O CRUZAMENTO, NESTE EXEMPLO OS CAMPOS SORTEADOS FORAM (D), (G), (I).....	144
FIG. D.3: INVERSÃO DE CONCENTRAÇÃO TIPO I. CAMPOS (E) E (F) DO PAI 1 PARA OS CAMPOS (H) E (I) DO FILHO 2 RESPECTIVAMENTE, CAMPOS (H) E (I) DO PAI 2 PARA OS CAMPOS (E) E (F) DO FILHO 1 RESPECTIVAMENTE. ....	144
FIG. D.4: INVERSÃO DE CONCENTRAÇÃO TIPO 2. CAMPOS (H) E (I) DO PAI 1 PARA OS CAMPOS (E) E (F) DO FILHO 2 RESPECTIVAMENTE, CAMPOS (E) E (F) DO PAI 2 PARA OS CAMPOS (H) E (I) DO FILHO 1 RESPECTIVAMENTE. ....	144
FIG. D.5:EXEMPLO DA OCORRÊNCIA DO PROCESSO DE MUTAÇÃO OCORRIDA NO CAMPO (F) DO CROMOSSOMO . ....	145

## Lista de Tabelas

TABELA 4.1: VARIÁVEIS DA CÉLULA SOLAR BASEADAS NO MODELO PMCCF – CÁLCULO DA ENTROPIA .....	58
TABELA 4.2: VARIÁVEIS DA CÉLULA SOLAR BASEADAS NO MODELO DETERMINÍSTICO - CORRELAÇÃO .....	60
TABELA 4.3: TABELA QUE REPRESENTA A MATRIZ DE COVARIÂNCIA .....	62
TABELA 4.4: VARIÁVEIS DA CÉLULA SOLAR BASEADAS NO MODELO DETERMINÍSTICO – VARIÁVEIS SELECIONADAS .....	68
TABELA 4.5: PARÂMETROS FÍSICOS UTILIZADOS PELO SOFTWARE PC-1D .....	70
TABELA 4.6: PROPRIEDADES COM ORDEM DE GRANDEZA ELEVADA .....	71
TABELA 4.7: PROPRIEDADES A SEREM CALCULADAS PELA RNA .....	72
TABELA 5.1: RESULTADOS ENCONTRADOS PELO SHG .....	79
TABELA 5.2: TIPO DE DOPANTE PARA O SEMICONDUTOR TIPO N .....	79
TABELA 5.3: MÉDIA DA CONCENTRAÇÃO DO DOPANTE TIPO N .....	79
TABELA 5.4: MÉDIA PARA A GRANDEZA DO DOPANTE N .....	80
TABELA 5.5: ELEMENTOS DOPANTE PARA O SEMICONDUTOR TIPO P .....	80
TABELA 5.6: MÉDIA DA CONCENTRAÇÃO DO DOPANTE TIPO P .....	80
TABELA 5.7: MÉDIA PARA A GRANDEZA DO DOPANTE TIPO P .....	80
TABELA 5.8: CONFIGURAÇÃO APRESENTADA COMO RESULTADO DO SISTEMA HÍBRIDO .....	81
TABELA 5.9: CARACTERÍSTICAS FÍSICAS DA CÉLULA SOLAR A SEREM ESTIMADAS PELA RNA .....	90
TABELA E.1: AVALIAÇÃO DO PROCESSAMENTO DA RNA PARA O MODELO PMCCF. ....	146
TABELA E.2: ESTRUTURA DA RNA PARA O MODELO PMCCF .....	146
TABELA E.3: FORMATAÇÃO DOS DADOS DA RNA PARA O MODELO PMCCF. ....	147
TABELA E.4: AVALIAÇÃO DO PROCESSAMENTO DA RNA PARA O MODELO PC-1D .....	148
TABELA E.5: ESTRUTURA DA RNA PARA O MODELO PC-1D .....	148

## Lista de Algoritmos

ALGORITMO 1: ALGORITMO DE TREINAMENTO DO PERCEPTRON.....	133
ALGORITMO 2: ALGORITMO DE MÁQUINAS LINEARES .....	134
ALGORITMO 3: ALGORITMO <i>BACKPROPAGATION</i> .....	138
ALGORITMO 4: ALGORITMO DE EXECUÇÃO DE UM AG .....	140

## Lista de acrônimos

$\Delta w$	Variação do peso da RNA
$\alpha$	Ângulo de rotação
$\delta_k$	Valor do erro para o neurônio k
$\varepsilon$	Erro máximo da estimativa
$\eta$	Taxa de aprendizagem
$\sigma$	Desvio padrão da população
$\mu$	Média da população
$\rho$	Momentum
$\lambda$	Autovalor
$A_i$	Resultado da função de avaliação
(Al)	Alumínio
(As)	Arsênio
AG	Algoritmo genético
ART	Adaptive Resonance Theory
a-Si:H	Silício amorfo hidrogenado
(B)	Bóro
$b_i$	bias (tendência)
c-Si	Silício Cristalino
$d$	Saída desejada para a RNA
$E$	Erro médio quadrático
$E[I(x)]$	Esperança de ocorrer o evento x
fc	Fator de curva
$f_A(i)$	Função fitness
GaAs	Arsenieto de Gálio
(Ga)	Gálio
gap	Energia de separação da camada de valência da camada de condução
$H(x)$	Valor da Entropia

HIT	Heterojunção de camada fina intrínseca
$I(x)$	Informação revelada pela variável $x$
IC	Inteligência computacional
IIR	Resposta de Impulso Infinito
(In)	Índio
$I_0$	Corrente reversa de saturação
Isc	Corrente de curto circuito
I <sub>mp</sub>	Corrente no ponto de potência máxima
$I_t$	Corrente total gerada pela célula solar
LM	Levenberg-Marquardt
LVQ	Learning Vector Quantization
MLP	Multi-Layer Perceptron
Mn	Manganês
MPPT	Rastreamento do ponto de potência máximo
N	Nitrogênio
$n$	Tamanho da amostra
<i>net</i>	Valor calculado pela RNA
$p_i$	Probabilidade de ocorrer o evento
(P)	fósforo
P	Dopante tipo P
PCA	Análise dos componentes principais
PPM	parte por milhão
PMCCF	Programa de modelagem computacional de células fotovoltaicas
PV	Fotovoltaico
$q$	Carga do elétron
$r$	Valor da correlação
RBF	Radial Basis Function
RNA	Rede neural artificial
rsh	Resistência Shunt
(Sb)	Antimônio



$s^2$	Estimativa do desvio padrão da amostra
$s_x^-$	Estimativa da média
$S_i$	Somatório dos pesos e saída da rede
$S^2(x_i, y_j)$	Covariância entre as variáveis x e y
(Si)	Silício
SIH	Sistema inteligente híbrido
SH	Sistema Híbrido
SHG	Sistema híbrido genético
SMV	Suport Vector Machine
SOM	Mapas auto-organizáveis
$t_{n-1}$	Distribuição de Student-Fisher
TCO	Óxido Condutor Transparente
Te	Telúrio
Vpmp	Tensão no ponto de potência máxima
Voc	Tensão em circuito aberto
$\bar{x}$	Média da amostra
$x_j$	Valor de entrada do neurônio j
$y$	Ponto de saturação da função de ativação
$w_{ij}$	Peso do neurônio i para o neurônio j
Zn	Zinco
$Z_{\alpha/2}$	Valor crítico para o grau de confiança

## Sumário

LISTA DE FIGURAS .....	VIII
LISTA DE TABELAS .....	XI
LISTA DE ALGORITMOS .....	XII
LISTA DE ACRÔNIMOS .....	XIII
<b>CAPÍTULO 1 – CONSIDERAÇÕES INICIAIS .....</b>	<b>1</b>
1.1 INTRODUÇÃO .....	1
1.2 O TRABALHO .....	6
1.3 ORGANIZAÇÃO DO TRABALHO .....	10
<b>CAPÍTULO 2 – O ESTADO DA ARTE.....</b>	<b>12</b>
2.1 INTRODUÇÃO .....	12
2.2 O LEVANTAMENTO BIBLIOGRÁFICO .....	12
<b>CAPÍTULO 3 – FUNDAMENTAÇÃO TEÓRICA SOBRE AS FERRAMENTAS DE IC.....</b>	<b>26</b>
3.1 INTRODUÇÃO .....	26
3.2 REDES NEURAIS ARTIFICIAIS (RNA).....	27
3.2.1 <i>Estrutura da RNA</i> .....	31
3.2.2 <i>Propriedades das RNA's</i> .....	32
3.2.3 <i>Formulação matemática do funcionamento da RNA</i> .....	39
3.3 ALGORITMOS GENÉTICOS .....	45
3.3.1 <i>Técnicas de aptidão</i> .....	47
3.3.2 <i>Resolução por método Heurístico</i> .....	48
3.4 SISTEMAS HÍBRIDOS .....	50
<b>CAPÍTULO 4 – PREPARAÇÃO DOS DADOS PARA SEREM UTILIZADOS COM AS FERRAMENTAS DE IC .....</b>	<b>52</b>
4.1 INTRODUÇÃO .....	52
4.2 PREPARAÇÃO DOS DADOS DO MODELO PMCCF .....	53
4.2.1 <i>Determinação das variáveis de entrada PMCCF</i> .....	55
4.3 PREPARAÇÃO DOS DADOS DO MODELO PC-1D .....	69
4.3.1 <i>Estimação dos parâmetros físicos do modelo PC-1D</i> .....	69
4.3.2 <i>Densidade de corrente</i> .....	71
<b>CAPÍTULO 5 - ANÁLISE DA APLICAÇÃO DOS DAS FERRAMENTAS DE IC AOS MODELOS DE TESTE .....</b>	<b>74</b>
5.1 INTRODUÇÃO .....	74

5.2	RESULTADOS DA MOD. DO SOFTWARE PMCCF COM O SIST. HÍBRIDO GENÉTICO (SHG) .....	74
5.2.1	<i>Execução e análise dos resultados SHG</i> .....	77
5.3	O MODELO PC-1D .....	88
5.3.1	<i>Análise da densidade de corrente</i> .....	90
5.4	REPRESENTAÇÃO GRÁFICA DOS MODELOS IMPLEMENTADOS .....	98
<b>CAPÍTULO 6 - CONCLUSÃO E DISCUSSÃO DOS RESULTADOS.....</b>		<b>101</b>
6.1	INTRODUÇÃO .....	101
6.2	DISCUSSÃO SOBRE A UTILIZAÇÃO DAS FERRAMENTAS.....	102
6.3	DISCUSSÃO SOBRE OS RESULTADOS ENCONTRADOS .....	103
6.4	CONCLUSÕES.....	105
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>		<b>107</b>
APÊNDICE A – ESTRUTURA DE UMA RNA E DE UM ALGORITMO GENÉTICO .....		<b>125</b>
APÊNDICE B – PRINCIPAIS ALGORITMOS UTIL. NO PROCESSO DE TREINAMENTO DA RNA. ....		<b>133</b>
APÊNDICE C – ALGORITMO DE EXECUÇÃO DE UM AG .....		<b>140</b>
APÊNDICE D – SISTEMAS HÍBRIDOS .....		<b>141</b>
APÊNDICE E – TAB. DE EXECUÇÃO DA RNA DE ACORDO COM CADA CONFIG. ....		<b>146</b>
APÊNDICE F – EQUACIONAMENTO DO MOD. MATEMÁTICO DET. DO MODELO PMCCF.....		<b>149</b>
ANEXO 1 – EQUACIONAMENTO DO MODELO MATEMÁTICO DO PC-1D. ....		<b>160</b>

# Capítulo 1

## Considerações Iniciais

### 1.1 Introdução


A produção de energia mundial, nos últimos dois séculos, esteve baseada principalmente na exploração de combustíveis fósseis como o petróleo, o carvão mineral, o gás natural entre outros, fazendo com que a economia de diversos países se tornasse dependente de uma matriz energética que é altamente nociva para o planeta. Até recentemente, boa parte dos economistas costumava lamentar o fato do petróleo ser um recurso finito, pois as economias de diversos países são galgadas nesses recursos e um colapso na produção de bens e transportes seria inevitável com o esgotamento dos mesmos [Sciam, 2009].

O desenvolvimento de novas tecnologias para o setor energético possui como finalidade a diversificação da matriz energética, buscando fontes menos poluidoras e ao mesmo tempo renováveis. Assim essas novas fontes de energia alternativa têm como foco a sustentabilidade, e vem atraindo cada vez mais consumidores e empresas preocupados com responsabilidade social e ambiental.

Em meados do século XIX, o físico-químico sueco Svante Arrhenius (1859-1927) realizou uma pesquisa onde o mesmo constatou que o dióxido de carbono é capaz de reter calor na atmosfera e, em consequência disso, sua maior concentração produziria inevitavelmente a elevação das temperaturas globais. Essa situação vem se agravando dia-após-dia pelo lançamento indiscriminado de toneladas de dióxido de carbono na atmosfera através da queima de combustíveis fósseis, principalmente em usinas termoeletricas, fábricas, carros etc.

Embora o aumento e o resfriamento da temperatura global seja algo próprio da natureza, esse processo leva milhares de anos e ocorre de uma maneira gradual, onde tanto

espécies animais quanto vegetais têm a grande possibilidade de se adaptar às mudanças climáticas. No caso da intervenção do homem, principalmente no que diz respeito à produção de  $\text{CO}_2$ , esse processo está se acelerando de uma maneira alarmante, como observado nos dois últimos séculos e apresentado na Figura 1.1, colocando em risco a sobrevivência de milhares de espécies da fauna e flora mundial, inclusive a do próprio ser humano. Esse processo acelerado está levando à ocorrência de eventos extremos com uma frequência nunca vista na história da humanidade e em todas as partes do mundo, tanto em países desenvolvidos, como em subdesenvolvidos ou em desenvolvimento [Moh, 2009].



**Fig. 1.1: Concentração de  $\text{CO}_2$  entre os anos 1840 e 2000**

O efeito estufa, com impacto direto nas mudanças climáticas, caminha rapidamente para se tornar o maior desastre ambiental da história da civilização, algo que antes disso, só se costumava atribuir a um conflito nuclear ou ao impacto de um bólido celeste como um cometa ou asteróide.

No caso do petróleo, embora sua necessidade na produção de energia seja evidente, deixa claro também que o desenvolvimento de novos recursos energéticos baseados em fontes alternativas de energia é uma necessidade real e não pode ser relegada para um futuro distante. Essas novas fontes energéticas devem ser renováveis e permitir a sustentabilidade da sociedade como um todo e em perfeito equilíbrio com o meio-ambiente e as metas de crescimento econômico das nações.

Segundo o climatologista James Hansen (1941-), do Instituto Goddard de Estudos Espaciais da NASA, os níveis de concentração de CO<sub>2</sub> na atmosfera foram estimados para o ano de 2009 em 383 ppm. Esse valor já seria superior ao limiar crítico estimado em 350 ppm. No que se refere ao aquecimento global e mudanças climáticas, uma mudança urgente na matriz energética dos países desenvolvidos e em desenvolvimento é necessária. Porém, as alternativas para produção de energia ainda estão longe da ampla aplicação comercial. Isso ocorre porque as fontes alternativas de energia não estão à altura, em termos de disponibilidade e competitividade comercial, com as fontes tradicionais de produção de energia.

Diversos são os desafios existentes no campo de pesquisa referente às fontes alternativas de energia. Onde é de senso comum que tão importante quanto encontrar uma nova forma de se produzir ou extrair energia renovável e limpa, é necessário também o aperfeiçoamento das mesmas no sentido de promover à sua competitividade. Assim como o atendimento de diversos critérios de mercado, como suprir a demanda energética e o preço final para o consumidor.

Logo, qualquer tecnologia de geração de eletricidade baseada em fontes renováveis deve atender a certo número de requisitos para se tornar viável comercialmente, como por exemplo, diminuir o custo do processo de fabricação e implementação, aumentar a eficiência no processo de geração de eletricidade, diminuir o custo final da eletricidade gerada, reduzir a emissão dos gases do efeito estufa, minimizar a agressão ao meio-ambiente e o tempo de retorno de capital etc [Pra, 2009][Pat, 1999][Mes, 2000].

Para ilustrar essa questão um comparativo pode ser feito, no caso da energia fotovoltaica, onde um dos principais empecilhos está relacionado com a disponibilidade de produção de energia [Tol, 2010][Editorial, 2010]. A questão fica evidente quando se observa o período útil de produção, limitado de 4 a 8 horas diárias, de acordo com a localidade onde está sendo produzida a energia [Bel, 2010]. Assim, nos demais períodos, a produção deve ser suprida por baterias ou pela rede elétrica externa.

Isso faz com que o custo do kW/h seja elevado e esteja na faixa de US\$ 0,47 a US\$ 0,70, enquanto a eletricidade fornecida pela concessionária em 24 horas de disponibilidade esteja por volta dos US\$ 0,11 para energia gerada por hidroelétricas e de US\$ 0,07 para energia gerada por termoeletricas a carvão mineral [Sciam, 2009]. Assim, o custo de

implantação de um sistema isolado ou híbrido com gerador diesel ou conectado na rede elétrica deve ser cuidadosamente avaliado através do viés econômico [Col, 2004][Elt, 2010].

Desta forma, pesquisas vêm sendo feitas para permitir o aperfeiçoamento do funcionamento de todas as fontes alternativas de energia, incluindo a conversão fotovoltaica. Nesse sentido um caminho que vem sendo apreciado é a utilização da simulação computacional do funcionamento desse tipo de dispositivo [Gow, 1999].

A simulação por computador vem se tornando uma prática bastante comum no meio científico e isso se deve ao fato de ser possível emular o comportamento de objetos, equipamentos e protótipos do mundo real através de modelos matemáticos e computacionais [Ger, 2002]. A gama de ferramentas existentes permite aos pesquisadores conseguir resultados rapidamente, viabilizar uma visualização do objeto de estudo sob diversos ângulos de forma que os mesmos possam antever resultados e comportamentos a partir de padrões de fabricação e operação [Yu, 2009]. Assim, as mais diferentes formas de operação e configuração podem ser testadas rapidamente com custos reduzidos e aproximação satisfatória, como é o caso de células solares, que podem ter diversas estratégias de construção independente de sua finalidade. Também podem atuar num diversificado contexto de operação onde diversos parâmetros podem ser rapidamente modificados, como descrito em Matos [Mat, 2006].

Existem várias estratégias para que se possa utilizar a simulação por computador [Bak, 2009], entre elas destacam-se a simulação a partir de um modelo matemático determinístico que estabelece o equacionamento e os relacionamentos pertinentes ao objeto de estudo, e a partir dele é elaborado o programa de simulação. Outra estratégia se refere à observação do comportamento do objeto de estudo para um conjunto de situações e a partir desse comportamento é encontrada a resposta para o objeto usando técnicas de inteligência computacional, como descrito em Mellit e Kalogirou [Ade 1, 2008]. Essas técnicas são adotadas principalmente em casos onde o estudo determinístico para as diversas situações de operação é bastante trabalhoso, demorado ou até inviável.

A utilização de técnicas que permitam identificar padrões, tendências e comportamentos em células solares caracteriza-se por uma estratégia de modelagem computacional para esse tipo de dispositivo. Para isso parte-se do princípio da observação

do seu comportamento em diversos cenários de operação, sua configuração construtiva e uma observação sobre o ciclo de vida de sistemas baseados em energia fotovoltaica [She, 2010].

O desempenho das células solares está alcançando os limites teóricos impostos pela física, e uma melhora de 1% na eficiência de conversão energética já apresenta uma grande significância [Editorial, 2008]. Para que se possam alcançar esses melhores resultados, uma compreensão ampla do funcionamento da célula solar será necessária. A forma menos dispendiosa de se chegar a esta compreensão é por meio de simulações computacionais, que permitem a um baixo custo e com resultados bastante fidedignos, uma observação plausível do mundo real.

Esse esforço para alcançar tal melhora de desempenho se justifica por que energia é uma das palavras que expressam mais preocupação em boa parte dos países [Silva, 2009][Sal, 2009][Mak, 2010][Ome, 2008]. Energia alternativa começa a se tornar realidade em projetos de grande escala, com novas cidades planejadas e ecologicamente corretas, como em *Treasure Island*, em *San Francisco*, Estados Unidos, com previsão de receber moradores a partir de 2013. *Dongtan*, em Xangai, China, que teve sua construção iniciada em 2009 e será um laboratório em escala urbana para aplicação de conceitos auto-sustentáveis de emissão zero de carbono e *Masdar*, em *Abu Dhabi* nos Emirados Árabes, com previsão de conclusão em 2016 [Sciam, 2009][Wang, 2010].

Aqui a participação da energia solar nas matrizes energéticas de diversos países tem se tornado uma realidade, como observado na Alemanha, com a instalação em 2010 de 6.500 MW, totalizando 16.300 MW de energia solar fotovoltaica instalada no país [EPIA, 2011]. Não só em países desenvolvidos observa-se essa tendência, mas também em regiões menos favorecidas e de difícil acesso, como é o caso da floresta amazônica no Brasil; onde está presente o maior sistema diesel isolado do mundo e o avanço da energia solar fotovoltaica possibilita as comunidades isoladas o acesso à energia elétrica e todos os seus benefícios [Mat, 2011].

O custo para a implantação global da mudança na matriz energética envolve refazer as feições do planeta, reconstruir cidades, reconsiderar desperdícios, implantar sistemas energeticamente eficientes e em harmonia com a natureza [Smi, 2000][Jos, 2009]. Um



custo incalculável, mas que, com certeza, será ínfimo se comparado ao custo destrutivo proporcionado pelo aquecimento global.

## **1.2 O Trabalho**

Este trabalho tem como objetivo o desenvolvimento de uma técnica de simulação computacional que permita observar o comportamento das células fotovoltaicas para uma dada condição de operação, e a partir dela estimar a configuração construtiva da mesma.

Sua contribuição científica se justifica principalmente pelo fato da minimização dos dados necessários para a determinação do comportamento da célula solar. Aliado a esse fato, a técnica proposta permitirá estimar os parâmetros físicos a partir do comportamento da célula solar, o que abre a possibilidade da realização de diversas análises comportamentais tanto no que se refere ao âmbito da caracterização elétrica, como também do comportamento físico que ocorre no interior da mesma. Isso dispensa a utilização de dados referentes ao processo de fabricação, permite o aproveitamento dos modelos disponíveis atualmente presentes em diferentes programas e base de dados para a composição das soluções das características da célula solar.


Quando se emprega o modelo determinístico, utilizado nos principais programas para modelagem computacional, é necessário ter conhecimento tanto de suas propriedades físicas, como também de algumas propriedades de fabricação da célula solar para alimentar o modelo com os dados necessários. Dentre as propriedades necessárias ao modelo, destacam-se a necessidade de se conhecer os tipos de dopantes utilizados e suas respectivas concentrações, índice de refração, densidade efetiva de estados, mobilidade de elétrons e lacunas, tempo de vida dos portadores minoritários, entre outros. Essas informações não são disponibilizadas por fabricantes, por se tratar de segredo industrial, podendo ser variáveis de célula para célula, dependendo da sua finalidade, falhas ou contaminação no processo de fabricação ou operação. Assim, a estimativa da composição da célula solar pode sofrer variações que irão influenciar no desenvolvimento de cenários e pesquisas relacionadas ao processo de fabricação, como a determinação de resistências paralelas, correntes de fuga ou capacitâncias internas, etc.

O modelo determinístico utiliza então um conjunto de dados necessários para a resolução das equações utilizadas, dados estes provenientes geralmente da literatura, pois os mesmos são de difícil aferição direta do objeto de estudo. Assim, esse modelo depende desse tipo de informação para calcular o desempenho da célula solar; fazendo com que, dependendo da característica a ser pesquisada, possa não refletir a realidade por ter interferência de diversas variáveis livres que influenciam no seu desempenho, como resistências, capacitâncias, velocidade de recombinação superficial, entre outros, que aparecem como ruídos e não conseguem ser identificados pelo modelo determinístico. Isso se deve principalmente ao fato dos dados utilizados no modelo determinístico serem estimativas ditas padrão, desconsiderando as especificidades únicas do objeto de estudo.

Dessa forma o modelo determinístico consiste na criação de uma função de transferência que toma dados de um domínio referente aos dados construtivos da célula solar e das respectivas condições de operação; que são mapeados para um contradomínio de soluções do problema que representa o comportamento da mesma segundo suas características I-V. Logo, se suas propriedades construtivas são conhecidas e uma condição de operação esteja estabelecida, é possível fazer o mapeamento único para uma solução do problema, conforme apresentado em [Mat, 2006] e representado pela Figura 1.2.

Porém, quando as propriedades construtivas não são conhecidas o mapeamento para comportamento da célula, em termos das suas características I-V, se torna deficitário e, em alguns casos, irreal. Este fato acaba por dificultar e até mesmo inviabilizar determinados tipos de análise sobre o objeto de estudo, como determinação de resistências, capacitâncias, comprimento da camada de depleção, velocidade e recombinação superficial, distribuição da densidade de portadores, entre outros.

A determinação das características construtivas da célula solar se faz necessária para a perfeita modelagem computacional do seu comportamento, e os principais valores referentes às propriedades físicas da célula podem ser estimados. Da mesma forma, a dimensionalidade das variáveis necessárias para o cálculo do seu comportamento pode ser reduzida a apenas um pequeno conjunto cuja sua principal propriedade é a fácil mensuração para sua rápida verificação e validação dos dados.

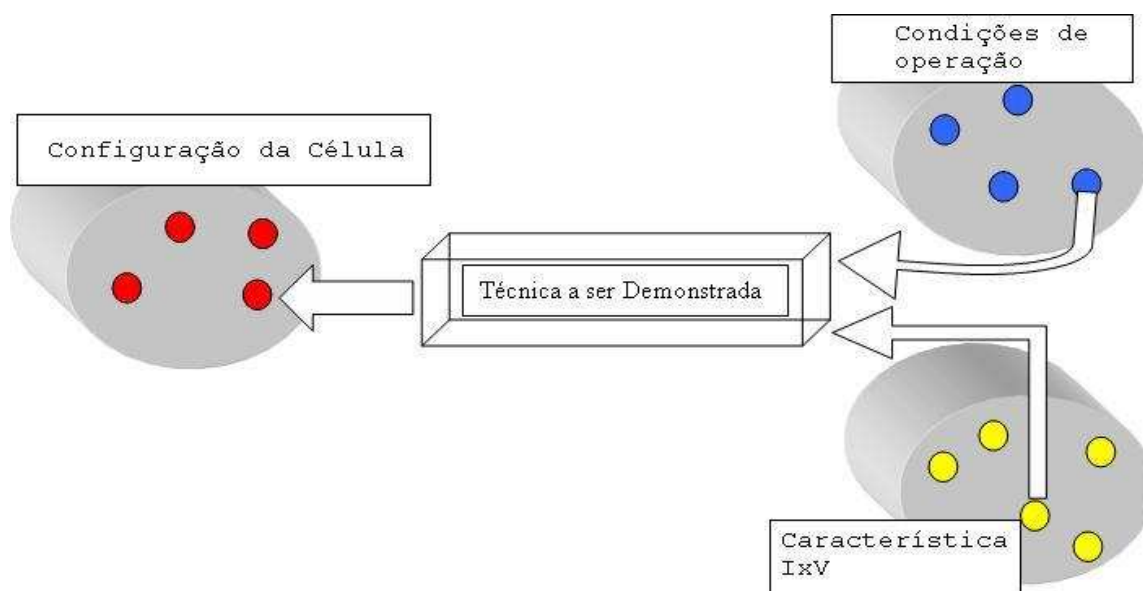


**Fig. 1.2: Ilustração do modelo determinístico**

Assim, o problema a ser solucionado consiste em criar uma técnica que possa estimar as possíveis configurações de fabricação da célula solar a partir da observação do seu comportamento para uma dada condição de operação. Ou seja, verificar a existência de uma função inversa à função de transferência apresentada em [Mat, 2006], onde seja possível determinar os elementos necessários para caracterizar o processo de manufatura da célula solar. Esses elementos a serem estimados, embora não apresentem todas as variáveis pertencentes ao processo de fabricação, contém como propriedade o fato de representar toda a informação necessária para a correta caracterização da célula solar. A Figura 1.3 apresenta o esquema da função de transferência a ser determinada.

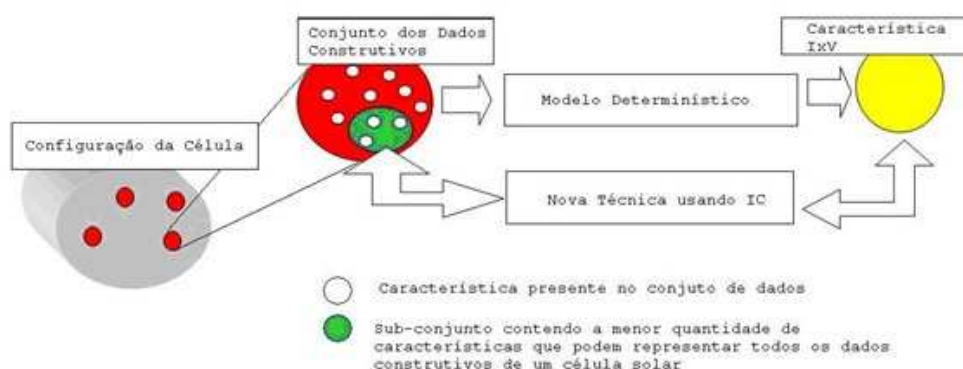
A busca por um modelo computacional que não seja dependente unicamente dos dados construtivos, mas sim dos dados colhidos da leitura comportamental da própria célula solar, vai possibilitar a validação de modelos, realização de análises, descrição de propriedades, métodos e características relacionadas ao objeto de estudo. O modelo proposto utiliza técnicas de Inteligência Computacional (IC) para que sejam estimadas as características construtivas, propriedades físicas e de operação da célula solar. Isso vai possibilitar uma melhor qualidade nos experimentos e dados relacionados por esse modelo. Logo novas características podem ser estudadas através de uma nova vertente, abrindo

novas possibilidades para a compreensão da fabricação, funcionamento e operação dos dispositivos [Kin, 1997][Ort, 2005], conforme apresentado na Figura 1.4.



**Fig. 1.3: Técnica Utilizando Ferramentas de IC.**

O trabalho toma como base o modelo implementado pelo programa para determinação das curvas I-V e P-V a partir das propriedades físicas da célula solar (PMCCF), desenvolvido na Universidade Federal de Uberlândia [Mat, 2006]. Isso para realizar os testes e análises referentes à validade da aplicação da técnica. Num segundo momento, a técnica é expandida para ser utilizada com o modelo implementado no software PC-1D. Isso por que o PC-1D é um dos principais programas de modelagem de células fotovoltaicas utilizados pela comunidade científica. Assim, com este trabalho espera-se demonstrar que a técnica possui forte embasamento matemático, o que credencia sua utilização, e é suficientemente genérico para cobrir diferentes tipos de modelos utilizados para caracterizar células fotovoltaicas.



**Fig. 1.4:** Novo padrão de determinação de I x V utilizando as técnicas de IC

### 1.3 Organização do trabalho

De forma a facilitar a compreensão do desenvolvimento do trabalho realizado e promover a integração das bases teóricas estudadas, esta tese está organizada da seguinte maneira.

No Capítulo 2 é apresentada uma pesquisa bibliográfica de forma a obter o estado da arte referente ao desenvolvimento da tecnologia de células fotovoltaicas como também no que se refere às pesquisas sobre ferramentas de inteligência computacional. Outro foco de especial atenção nessa revisão da literatura refere-se ao levantamento dos softwares utilizados para a modelagem de células solares, nesse sentido destacando o uso do software PC-1D, utilizado para a validação da técnica.

O Capítulo 3 refere-se à fundamentação teórica sobre o funcionamento das ferramentas de IC utilizadas neste trabalho. Serão apresentados os conceitos referentes às Redes Neurais Artificiais (RNA), Algoritmos Genéticos (AG) e Sistemas Híbridos Genéticos (SHG).

No Capítulo 4 é apresentada a metodologia utilizada para o tratamento das variáveis presentes nos modelos de teste (PMCCF e PC-1D). São realizadas diversas análises, como a análise dimensional, de entropia, covariância e análise dos componentes principais.

No Capítulo 5 é apresentada a aplicação da técnica para os conjuntos de dados estudados para ambos os modelos de teste. Os resultados são apresentados por meio de gráficos e tabelas onde é possível verificar a similaridade da técnica proposta com os resultados dos modelos de teste.

No Capítulo 6 é realizada a discussão dos resultados encontrados e apresentada as conclusões da pesquisa sobre o uso da técnica, sua contribuição científica e propostas para a realização de trabalhos futuros.

# Capítulo 2

## O Estado da Arte

### 2.1 Introdução

A busca do estado da arte parte de uma pesquisa detalhada nas mais conceituadas revistas da área de energia solar, como *Solar Energy Materials & Solar Cells*, *Physical Review Letters*, *Progress in Energy and Combustion Science*, *Renewable & Sustainable Energy Reviews*, *Solar Energy*, *Renewable Energy*, *Energy Conversion and Management*, *Applied Energy*, *Applied Physics & Materials - Science & Processing*, *Neural Networks*, *Journal of Applied Physics*, *Journal of Intelligent and Robotic Systems*, *European Photovoltaic Industry Association*, *Renewable Energy*, e outras que são referência para o setor. Além dos artigos em revista, estão presentes nesse estudo bibliográfico os artigos dos congressos e livros especializados referentes ao tema de pesquisa desse trabalho.

### 2.2 O Levantamento bibliográfico

O levantamento bibliográfico inicia-se pelo trabalho de Braga et. al.[Afb, 2008], onde o artigo trata das novas estratégias para a fabricação de células solares de baixo custo. Esse trabalho é focado nas diversas técnicas utilizadas no processo de fabricação de células solares baseadas em silício policristalino. Embora tenha um rendimento menor que o silício monocristalino, seu menor consumo de energia no processo de fabricação acaba por destacá-lo como uma alternativa viável para o mercado. O artigo trata do processamento dado ao silício de grau metalúrgico para que o mesmo possa atingir o grau solar e ser utilizado para a fabricação de células solares p-Si.

A preocupação com o processo de fabricação também é evidenciado no trabalho de Chu et. al. [Chu, 2009], que trata do custo para a fabricação de camadas de silício cristalino em formato de pirâmide com orientação 100 para o melhor aproveitamento da luz solar. Uma observação interessante é que o uso da simulação computacional por meio de redes neurais se encaixa perfeitamente nesse tipo de trabalho, isso por que independente se a célula solar é feita de silício monocristalino, policristalino, amorfo hidrogenado, polímeros, entre outros tipos, suas características físicas poderiam ser emuladas. Diferente do modelo determinístico que apresenta modelos empíricos diferenciados para as células solares baseadas em silício monocristalino, policristalino e todos os outros demais tipos.

Uma aplicação dos processos de produção e desenvolvimento de células solares pode ser observado no artigo de Tsunomura et. al. [Tsun, 2009] onde é apresentado uma célula solar com eficiência em conversão elétrica de 22,3%, utilizando heterojunção com uma estrutura de uma fina camada intrínseca (HIT) de a-Si:H/c-Si (silício amorfo hidrogenado e silício cristalino).

A preocupação com a certificação dos resultados de eficiência em conversão elétrica das células fotovoltaicas pode ser observado no editorial da revista *Solar Energy Materials & Solar Cells* (2008) [Editorial, 2008]; que recomenda aos pesquisadores que se faça uma validação dos resultados experimentais em laboratórios ou institutos certificados quando os resultados de eficiência no processo de conversão da célula solar apresentar uma melhoria para valores acima de 5%.

No trabalho de Reich et. al. [N.H. Rei, 2009] são investigadas as características de tensão e corrente da célula solar quando estas estão submetidas a baixas intensidades luminosas ( $0,01$  a  $100 \text{ w.m}^{-2}$ ) por meio da medição de 41 células comerciais de oito fabricantes diferentes. As medições permitiram comparar quatro modelos utilizados para medir as características da célula solar. Foram eles: *fill factor*, função puramente empírica, modelo de um diodo e modelo de dois diodos, onde foi observado que os modelos de dois diodos têm boa precisão quando submetidos à baixa intensidade luminosa, diferentemente dos demais modelos. Com essa pesquisa, pode-se observar que não existe uma relação linear entre a intensidade luminosa e a resposta da célula solar.

A pesquisa por novos materiais e métodos mais eficazes de absorção do espectro solar é recorrente no meio científico e busca novas estratégias, como apresentado por B.



Das e S.P. McGinnis [B. Das, 2000]. Nesse artigo é apresentado um novo modelo baseado em tecnologia para a fabricação de grandes matrizes periódicas de nanoestruturas semicondutoras apropriadas para a fabricação de uma variedade de semicondutores, dentre eles células solares multicamadas. Segundo o artigo de B. Das e S.P. McGinnis, assim como as células solares multicamadas, as células solares baseadas em filmes finos são promissoras para aplicações comerciais em grande escala devido ao seu baixo custo de fabricação. No entanto, um grande problema com a tecnologia de película fina é que o material não apresenta uniformidade com a fabricação de filmes de grande área de superfície. A utilização da técnica de fabricação baseada em *template* para desenvolver alta eficiência de células solares com base em nanoestruturas de semicondutores poderá eliminar o problema da não uniformidade espacial, mantendo a vantagem do baixo custo de fabricação da película fina. Assim, segundo B. Das e S. P. McGinnis, esta tecnologia irá fornecer (i) alta eficiência, (ii) baixo custo de fabricação, e (iii) confiabilidade a longo prazo.

Da mesma forma, um artigo publicado por K. Yu et al., apresentado na revista *Physical Review Letters*, descreve um novo material semicondutor que os autores afirmam poder obter as células solares com eficiências de até 56%. No padrão de células solares a luz absorvida pela célula é convertida em energia, liberando um elétron da camada de condução, permitindo o fluxo de corrente. Com base nas propriedades do semicondutor especial utilizado na célula, os fótons devem ter certa quantidade de energia para excitar o elétron. O novo material, um cristal, cuja composição fazem parte o ZnMnTe, foram adicionadas impurezas de oxigênio, como ele tem três bandas proibidas em vez de uma, é possível tirar vantagem dessa característica fazendo com que uma faixa mais larga do espectro de energia solar seja aproveitada. Os pesquisadores sintetizaram o material que utiliza uma nova técnica chamada de implantação de íons de oxigênio por fusão laser pulsado.

Assim como a pesquisa por novos materiais, o desenvolvimento de novas técnicas e de novos modelos para a compreensão das células fotovoltaicas vem sendo desenvolvidos. Isso pode ser observado no trabalho de Chin-Yi Tsai [Chi, 2006]. O modelo teórico para o cálculo do coeficiente de ganho óptico em semicondutores com bandas *GAP* indiretas é apresentado. O modelo incorpora todos os oito processos possíveis de interação fóton-

fóton tanto de emissão e absorção, que são fundamentais em células solares baseadas em silício e germânio.

Uma mostra de que o processo de simulação computacional pode favorecer a compreensão e o aperfeiçoamento de células fotovoltaicas pode ser observado no artigo de L. Zhao et. al. [L. Zhao, 2008] que trata do uso do software *AFORS-HET* no estudo da heterojunção com camada fina intrínseca (HIT) em células solares fabricadas em silício tipo P. Nesse trabalho foi verificada a influência da estrutura de diversos parâmetros sobre o desempenho do c-Si(p) com base em células solares HIT bifacial, ou seja, cuja composição é dada por TCO / a-Si:H(n) / a-Si:H(i) / c-Si(p) / a-Si:H(i) / a-Si:H(p+) / TCO. O estudo foi realizado em detalhe por simulação numérica em computador como foi feito no software *AFORS HET*. A função trabalho do óxido condutor transparente (TCO) foi encontrada para ser um fator chave a afetar o desempenho da célula solar.

No trabalho de AlRashidi et. al. [Air, 2011] uma nova proposta para a extração das características da curva I-V para célula fotovoltaica é apresentada. Nesse artigo é utilizado o modelo de dois diodos para realizar os cálculos dos parâmetros que são a fotocorrente gerada, a corrente de saturação, a resistência em série, a resistência shunt e os fatores de idealidade dos diodos. Também é realizado um estudo comparativo com outros trabalhos como os realizados por Easwarakhanthan et. al. [Eas, 1986] e Bouzidi et. al. [Bou,2007] e por uma ferramenta utilizando algoritmos genéticos.

Nos trabalhos de Rodrigues et. al. [Rod, 2011] e [Rod-2, 2011] são realizadas análises da curva I-V para a determinação dos parâmetros para o modelo de um diodo da célula solar. Para o cálculo dos parâmetros pesquisados são utilizados os pontos da curva I-V formados pelo par ordenado tensão e corrente que contém as seguintes informações: a voltagem no ponto de curto-circuito (0V), a voltagem a 30% do ponto de circuito aberto, o ponto de máxima potência, a voltagem a 90% do ponto de circuito aberto e a voltagem no ponto de circuito aberto (Voc). Para cada um desses pontos, o par ordenado de tensão e corrente é utilizado para o método da região de confiança para se determinar os parâmetros do modelo de um diodo, que são: a fotocorrente gerada, a corrente reversa de saturação, o fator de idealidade do diodo, a resistência shunt e a resistência em série.

O software *AFORS-HET* também é utilizado no trabalho de Stangl et. al. [Stan, s.d.] onde é descrito uma simulação computacional de células solares de filme fino formadas por

heterojunção, mostrando a importância da utilização de diversos modelos para a perfeita compreensão dessa tecnologia. Outro método de análise do desempenho da célula solar referente ao ponto de carga ótimo é realizado no trabalho de Jinlei e Rakesh [Din, 2008].

A simulação de células fotovoltaicas também pode ser feita pelo software *PC-ID*. A versão 5 de 32 bits desse software foi apresentada durante o 26<sup>th</sup> *IEEE Specialist Conference* [Clu, 1997]. O *PC-ID* é utilizado para modelar células solares cristalinas, permitindo a rápida visualização gráfica dos resultados encontrados. O modelo utilizado nesse software utiliza a resolução por elementos finitos para solucionar as equações de transporte de portadores em uma dimensão.

O *PC-ID* foi utilizado em diversos trabalhos para a verificação de resultados simulados, como no artigo de Abderrahmane Belghachi e Abderrachid Helmaoui [Abd, 2008]. O trabalho trata do efeito de campo na superfície de uma célula solar de GaAs. São investigadas as características que podem influenciar na melhora de desempenho da célula solar. O trabalho apresenta uma simulação da influência do GaAs em termos de resposta espectral da célula solar e foto-corrente disponibilizada pela mesma. O modelo é baseado em uma simples abordagem analítica através da variação da concentração dos dopantes.

Também no trabalho de Bultman et. al. [But, 2001] é utilizado o software *PC-ID* para o estudo de emissores seletivos em células solares de silício cristalino, onde um novo método é utilizado para esse processo e a aplicabilidade dos emissores seletivos para a produção em larga escala de células solares de silício multicristalino. O software *PC-ID* foi utilizado para confirmar os resultados do modelo proposto.

No trabalho de Lipiński e Panek [Lipi, 2003] é investigada a célula solar de silício monocristalino com metalização por serigrafia. A eficiência típica da célula é de aproximadamente 15%. A participação de todos os fatores responsáveis pela redução da eficiência são obtidos com base na simulação no programa *PC-ID*. Ele apresenta um perfil do dopante doador no emissor  $n^+$ , que é um fator crítico que reduz a eficiência da célula solar para cerca de 9% em comparação com valor máximo teórico. Outros fatores como a refletância, resistências em série e a alta corrente de saturação também são investigadas como fatores de redução da eficiência da célula solar.

No trabalho de Habbou, Chaffoui e Hartiti [Hab, 2007] é apresentada a metodologia Taguchi para a otimização da eficiência de conversão de células solares de silício tipo

$n^+pp^+$ . Nesse estudo é discutida a influência dos parâmetros na eficiência da célula solar, onde esses parâmetros são determinados por meio de simulação numérica pelo software *PC-1D*.

Durante a 25<sup>th</sup> *European Photovoltaic Solar Energy*, em 2010, Eidlloth, Eitner, Steingrube e Brendel [Eid, 2010] apresentaram um artigo que trata do uso da modelagem numérica para a compreensão do desempenho de células solares. Uma rápida comparação com o software *PC-1D* é realizada, e a solução do mesmo é por meio de modelos unidimensionais. No artigo de Eidelloth, uma proposta de uma Interface Gráfica de Usuário (GUI) para solução bidimensional é apresentada como um pacote para uso em conjunto com o Matlab. Por ser um pacote *open-source*, a modelagem de parâmetros da célula solar, para o cálculo de simulação, poderia ser utilizado por diferentes tipos de programas. O software resolveria um conjunto completo de equações de transporte em semicondutores utilizando o módulo *COMSOL Multiphysics*.

No trabalho de Koran et. al. [Kor, 2009] é desenvolvido um simulador fotovoltaico que utiliza curvas de referência de um sistema fotovoltaico real que são analisados por meio de um circuito analógico de controle. Esse método não utiliza equações empíricas, mas sim um conjunto de dados armazenados para realizar a comparação com os dados de entrada do circuito.

A simulação computacional da célula fotovoltaica também pode ser feita por meio do circuito elétrico equivalente, onde o fator de idealidade do diodo, obtido da junção *pn* da célula solar, apresenta impacto direto na qualidade do modelo descrito; como apresentado no trabalho de Singh et. al. [Sin, 2009] e deve possuir um valor de idealidade entre 1 e 2. Nesse trabalho é introduzida a teoria da função *trans especial* para calcular o fator de idealidade da junção *pn* e comparando-o com os valores obtidos através de outros métodos presentes na literatura.

Outra forma de simulação computacional é descrita por F. B. Matos e J. R. Camacho [Mat, 2008], que busca determinar como as propriedades físicas das células fotovoltaicas baseadas em silício (Si) sofrem influência dos componentes utilizados na composição dos semicondutores tipo N e tipo P. Essa influência se manifesta principalmente no comportamento da camada de depleção. Desta forma é possível observar neste trabalho que as alterações dos dopantes utilizados irão afetar tanto a barreira

potencial, quanto o comprimento da camada de depleção, modificando a corrente reversa de saturação e a tensão em circuito aberto, como também as características de tensão e corrente da célula.

No trabalho de J.A. Grow e C.D. Manning [J.A. Grow, 1999] é apresentada uma base de um circuito elétrico para a construção de modelos computacionais para simulação das características I-V de sistemas fotovoltaicos a partir de uma determinada célula fotovoltaica. As variáveis são a irradiância e a temperatura da célula instalada num módulo (painel) fotovoltaico. O modelo pode ser implantado em softwares como o *SPICE* ou o *SABER* ou ainda, o desenvolvimento de softwares próprios que utilizem os esquemas elétricos apresentados.

Já no trabalho de Brown et. al. [Bro, 2010] é utilizada uma aproximação através de elementos finitos para simular a eficiência de conversão elétrica de células solares compostas por  $\text{In}_x\text{Ga}_{1-x}\text{N}$ . Nesse trabalho é observado que tanto a espessura da camada de depleção quanto à dopagem dos semicondutores afetam de maneira significativa o desempenho da célula.

A simulação de arranjos fotovoltaicos está descrita no trabalho de Villalva et. al. [Vil, 2009] que utiliza os parâmetros do *datasheet* do módulo para realizar a simulação do modelo por meio de um circuito simulador.

A dependência da temperatura, da tensão de circuito aberto ( $V_{oc}$ ) e do *fill factor* ( $FF$ ) de uma célula solar de silício têm sido investigados no intervalo de temperatura 295-320K, como tratado no trabalho de Priyanka Singh et. al. [Pri, 2008]. Esse trabalho trata da taxa de redução de  $V_{oc}$  com temperatura ( $T$ ) e como é controlado pelos valores da energia *gap*, a resistência *shunt* ( $r_{sh}$ ) e suas taxas de variação com a temperatura. Descobriu-se que  $r_{sh}$  diminui devido ao efeito da temperatura e afeta diretamente  $dV_{oc}/dT$ , que representa uma importante variação para as células fotovoltaicas com valores menores de  $r_{sh}$ . A resistência em série também muda quase linearmente com a tensão, fazendo com que o *fill factor* dependa não apenas do valor de  $r_{sh}$ , mas também de outros parâmetros, como a taxa de variação de resistência com a tensão.

Segundo o artigo de Andres Cuevas e Jason Tan [And, 2009], que trata da modelagem teórica das características de células solares de silício em condições extremas de recombinação superficial e de forte intensidade de iluminação. O artigo prevê desvios

nas curvas características padrão I-V, mostrando que eles são devidos à difusividade finita dos portadores que atingem a superfície.

A modelagem computacional também pode ser utilizada como critério de decisão para empreendimentos fotovoltaicos, como descrito no trabalho de Carrion et. al. [Car, 2008] que propõe um sistema que analisa diversos critérios para auxiliar na decisão de implantação de uma planta fotovoltaica conectada à rede elétrica.

O trabalho de Adel Mellit e Soteris A. Kalogirou [Ade 1, 2008] trata de como as técnicas de inteligência artificial se apresentam como ferramentas úteis numa abordagem alternativa a metodologia determinística e as técnicas convencionais em aplicações de sistemas fotovoltaicos. Essa nova abordagem tem sido utilizada para solucionar problemas práticos em várias áreas, onde pode se destacar como as principais características, o poder de aprender a partir de exemplos, serem tolerante a falhas no que se refere a lidar com dados ruidosos e principalmente incompletos. Ela ainda tem a capacidade de lidar com problemas não lineares e de extrema complexidade e, uma vez treinada para certa configuração de problema, pode realizar a previsão e generalização de resultados em alta velocidade e com grande precisão.

A aplicação de sistemas baseados em técnicas de inteligência computacional engloba as áreas de modelagem, identificação, otimização, previsão, regressão e controle de sistemas complexos, entre outros. Assim, o trabalho de Mellit e Kalogirou esboça um entendimento de como as técnicas de inteligência artificial resolvem uma série de problemas na aplicação de sistemas fotovoltaicos. Um grande destaque é dado ao uso de redes neurais artificiais. Os principais problemas apresentados no artigo incluem previsão e modelagem de dados meteorológicos, dimensionamento de sistemas fotovoltaicos e de modelagem, simulação e controle de sistemas fotovoltaicos. Isso demonstra como essa abordagem alternativa desempenha um papel importante e decisivo no processo de projeto de engenharia em fontes alternativas de energia.

Num outro trabalho, Adel Mellit et al. [Ade 2, 2008] apresenta uma visão geral de como as técnicas de inteligência computacional, principalmente o uso de redes neurais artificiais, são utilizadas para o dimensionamento de sistemas fotovoltaicos como sistemas autônomos, sistemas fotovoltaicos interconectados a rede elétrica, sistemas fotovoltaicos híbridos com sistema eólico ou gerador diesel. Nesse trabalho é explorado o potencial das

redes neurais artificiais como uma ferramenta de projeto para o correto dimensionamento de sistemas fotovoltaicos. Além disso, a vantagem de usar essa técnica de inteligência computacional para o dimensionamento é que ela proporciona bons resultados de otimização, especialmente em áreas isoladas, onde os dados meteorológicos nem sempre estão disponíveis e necessitam serem estimados, como apresentado no trabalho de Pereira et. al. [Per, 2006][Per, 1998].

Para a utilização da energia fotovoltaica é necessário conhecer o regime de radiação solar de uma determinada região de forma a determinar a viabilidade técnica e econômica da mesma, para isso pode ser utilizado uma rede de radiômetros presentes na região, apoiados por técnicas estatísticas e de interpolação de dados. Porém, quando os radiômetros estão localizados a uma distância superior a 45 km os resultados começam a se tornar pouco confiáveis. Outra forma para determinar a intensidade de radiação local é através da resolução da equação de transferência radiativa, conforme descrito no trabalho de Pereira et. al. [23] e Martins et. al. [Mar 1, 2006] [Mar 2, 2006].

No trabalho de Almonacid et. al. [F. alm, 2008] o uso das redes neurais artificiais foi utilizada para caracterizar o comportamento de painéis fotovoltaicos de silício cristalino, isso porque no campo da energia solar, os fabricantes fornecem avaliações de módulos fotovoltaicos para as condições referidas como condições de teste padrão, realizadas em laboratório sob condições controladas, geralmente a 25 °C e a 1000 W.m<sup>-1</sup>. No entanto, estas condições raramente ocorrem no meio ambiente onde serão instalados os módulos fotovoltaicos. Para a utilidade e aplicabilidade da classificação de operação do painel, dentro de condições normais de ensaio dos módulos fotovoltaicos, acaba-se criando uma questão controversa sobre o desempenho desses módulos em condições reais de operação [Kin, 1997]. Portanto, para realizar a engenharia de módulos fotovoltaicos, é necessária uma caracterização adequada do comportamento do módulo fotovoltaico em termos de suas curvas características de tensão e corrente elétrica (curvas I-V). Foi desenvolvido um método baseado em redes neurais artificiais (RNA's) para analisar as curvas comportamentais dos módulos fotovoltaicos.

Uma RNA treinada tem sido utilizada e é capaz de gerar as curvas características I-V dos módulos de silício cristalino para qualquer irradiância e temperatura das células constituintes do módulo. Os resultados mostram que a RNA proposta introduz uma boa

previsão para o desempenho dos módulos de silício cristalino quando comparado com os valores medidos.

Em outro artigo, Adel Mellit et. al. [Ade, 2007] apresenta uma proposta para o dimensionamento de sistemas fotovoltaicos isolados a partir da utilização de uma rede neural adaptativa combinada com o algoritmo de Levenberg-Marquardt (LM) com uma Resposta de Impulso Infinito (*IIR*). O estudo apresenta o dimensionamento do gerador fotovoltaico, banco de baterias e regulador de tensão a partir das características climáticas as quais o sistema está submetido. Os resultados simulados apresentam entre 90% e 96% de correlação com os resultados reais medidos de um sistema instalado no sul da Argélia. Também é realizada uma comparação com o modelo baseado em *Multi-Layer Perceptron (MLP)* e *Radial Basis Function (RBF)*.

No trabalho de Wu et. al. [Wu, 2009] é utilizado uma aplicação computacional baseada em redes neurais artificiais para identificar e diagnosticar falhas em sistemas fotovoltaicos, onde as propriedades de identificação, reconhecimento e generalização são exploradas para a determinação das possíveis falhas no processo.

O trabalho de Karatepe et. al [Eng, 2006] apresenta uma abordagem baseada em redes neurais para melhorar a precisão do circuito elétrico equivalente de um módulo fotovoltaico (PV). Os parâmetros do circuito equivalente de um módulo PV dependem principalmente da irradiação solar e da temperatura das células fotovoltaicas. Essa dependência de fatores ambientais influencia os parâmetros do circuito onde é investigado um conjunto de curvas de corrente pela tensão. No trabalho é apresentado que a relação não é linear entre os parâmetros do circuito equivalente e as condições ambientais de operação, fazendo com que a expressão por uma equação analítica seja extremamente difícil, assim, a rede neural é utilizada para superar essas dificuldades. Segundo Karatepe a rede neural é treinada uma vez usando algumas medidas das curvas de correntes e tensão e os parâmetros do circuito equivalente são estimados somente lendo as amostras de irradiação solar e temperatura muito rapidamente, sem qualquer solução de equações não-lineares implícitas onde seria necessário o uso de métodos convencionais. A comparação entre os valores medidos e os resultados do modelo proposto apresenta maior precisão do que o modelo convencional para todas as condições de funcionamento.



A análise e acompanhamento dos pontos de máxima potência (*MPPT*) foi descrito no trabalho de Cheikh, et. al. [M.S. Ait, 2006], onde um método de controle para o acompanhamento do *MPPT* de um sistema fotovoltaico, onde o objetivo de aumentar a potência de saída do sistema através da utilização de redes neurais.

Um controlador eletrônico interno entre o gerador fotovoltaico e a carga é utilizado, cujo papel principal é o acompanhamento permanente do ponto de potência máxima do gerador fotovoltaico. Ele foi comparado com outros métodos de acompanhamento em regime de potência máxima baseados em algoritmos de perturbação e observação e em algoritmos com a utilização de processos iterativos. A RNA apresentou melhora no valor de potência, bem como no tempo de resposta, principalmente devido ao fato da demora na convergência dos dados dos métodos comparados (no caso dos algoritmos iterativos) e na precisão dos dados (no caso dos algoritmos baseados em perturbação e observação). As simulações realizadas mostram que mesmo sob diferentes condições atmosféricas o controlador neural respondeu melhor do que os métodos comparados, permitindo reduzir os inconvenientes que aparecem utilizando estratégias tradicionais.

No trabalho de Basso [M. Bas, 2005] é relatada a experiência com a aplicação de um processo não linear e auto-regressivo com o uso de RNA's, onde um modelo de turbina a gás da usina de *Nuovo Pignone* é modelada. Duas condições de funcionamento da turbina são consideradas: modo isolado e modo de operação não isolado. Os parâmetros do modelo são estimados iterativamente pela RNA, explorando tanto as características de operação quanto as características de fabricação da turbina a gás. Muitos índices foram avaliados e comparados a fim de realizar a seleção de um subconjunto da base funcional para definir e determinar a estrutura do modelo não linear. Assim, diversos sinais de entrada para aplicação e validação foram considerados durante a modelagem.

No trabalho de Ming Qu et. al. [Min, 2003] as RNA's são utilizadas para classificar as características e tipos de explosões solares que ocorrem na superfície do sol que interferem de maneira significativa nas comunicações aqui na terra. Nesse trabalho é realizado o comparativo entre Redes *Multi-Layer Perceptron* (MLP), *Radial Basis Function* (RBF) e *Support Vector Machine* (SMV).

O uso de RNA's como ferramentas de modelagem de sistemas dinâmicos vem se tornando cada vez mais comum devido às suas características em classificar grupos,

reconhecer padrões e inferir ou generalizar conhecimento. Isso pode ser observado no trabalho de Skoundrianos e Tzafestas [E. N. Sko, 2004] que trata do uso de redes MLP para a modelagem de sistemas dinâmicos e discretos no tempo, onde uma nova função de ativação sigmoideal é proposta e analisada num sistema de três tanques.

A utilização dessa ferramenta também pode ser observada no trabalho de Ashhab [Ash, 2008] que trata da modelagem de sistemas fotovoltaicos integrados (fotovoltaico e térmico) por meio da utilização de redes neurais artificiais. O sistema toma como entrada de dados a irradiância solar, temperatura, velocidade do vento, temperatura da água nos coletores, fluxo de água, tensão e corrente do painel fotovoltaico para determinar a melhor configuração de operação do sistema, de forma a maximizar sua eficiência. Para isso é utilizado o algoritmo *Backpropagation* presente numa rede neural MLP (*Multi-Layer Perceptron*).

Já no trabalho de Ludwig, Jr e Eduardo Montgomery [Lud, 2007] são apresentados os fundamentos de diversos tipos de RNA com suas respectivas fundamentações práticas e teóricas e aplicações em diversas áreas da engenharia, destacando as características de cada tipo de RNA para a solução de um determinado tipo de problema.

No trabalho de Lin e Phillips [Lin A., 2008] é utilizada outra ferramenta da área da inteligência computacional para se determinar as características ópticas de filmes finos, de forma a melhorar o desempenho do sistema por meio da difração e reflexão. Nesse trabalho são utilizados algoritmos genéticos capazes de modelar o comportamento da difração e sua influência na resposta da célula solar tendo como base os filmes finos.

Outra ferramenta utilizada para se determinar as características através do reconhecimento de padrões por meio de RNA's está descrito no trabalho de K. L. Du [K. L. Du, 2010] que utiliza o processo de clusterização para a análise de dados. Além da análise de dados é possível realizar a extração de características, segmentação de imagens, aproximação de funções e mineração de dados. Por meio da técnica de clusterização é possível identificar estruturas inerentes do conjunto de dados analisados e agrupá-los conforme suas propriedades em comum através da utilização de modelos estatísticos ou por meio do aprendizado competitivo.

No trabalho de Araujo et. al. [Ara, 2006] são utilizadas as ferramentas de inteligência computacional para a previsão de séries temporais através de uma abordagem

híbrida evolucionária, onde o emprego de redes neurais artificiais e algoritmos genéticos são utilizados.

No trabalho de Lee [Lee T., 2008] é utilizada uma rede neural treinada com o algoritmo *Backpropagation* para prever o surgimento de tempestades no arquipélago de *Taichung* em *Taiwan*. É realizado um comparativo com o método numérico a partir de modelos hidrodinâmicos e por fórmulas empíricas. O modelo utilizando redes neurais permite uma previsão eficiente com cerca de 1 a 6 horas de antecedência.

A modelagem do consumo residencial de energia elétrica é investigada por meio da implantação de redes neurais artificiais, conforme apresentado no trabalho de Aydinalp [Ayd, 2002] onde a utilização da rede neural é comparada com o método de verificação da análise de demanda condicional. Através da utilização da RNA é possível determinar relacionamentos casuais através de um grande número de parâmetros que envolvem o setor residencial.

Um exemplo da utilização de sistemas híbridos baseados na solução por Algoritmos Genéticos (AG's) e RNA's pode ser observado no trabalho de [Hag, 2003] que consiste na operação dos sistemas de abastecimento de água. Neste trabalho apresenta-se um algoritmo genético híbrido que permite determinar as estratégias de operações com custos energéticos reduzidos. A análise do modelo é feita em um estudo de caso real localizado na cidade de Ourém (Portugal). A RNA é utilizada para simular o funcionamento do sistema híbrido, enquanto o AG é utilizado para encontrar respostas de forma a reduzir o consumo de energia do sistema. O AG gera resultados que podem ou não ser factíveis para um determinado cenário de operação que é dinâmico e se modifica a cada hora, assim, a RNA intervêm nas soluções encontradas pelo AG de forma a gerar cenários factíveis para a solução do problema. Esta técnica encontra respostas ótimas, cerca de 20 vezes mais rápido do que os métodos utilizando programação linear ou somente a utilização de algoritmos genéticos.

Como descrito nesse capítulo, o levantamento bibliográfico permitiu não somente apurar o estado da arte no que se refere à modelagem computacional de células fotovoltaicas e utilização das ferramentas de Inteligência Computacional (IC) para o cenário de simulação focando fontes alternativas de energia; mas também possibilitou a obtenção das bases teóricas que fundamentam o estudo. A apresentação detalhada desses

fundamentos teóricos será apresentada no capítulo a seguir que trata da fundamentação teórica das ferramentas de inteligência computacional.

# Capítulo 3

## Fundamentação Teórica sobre as Ferramentas de Inteligência Computacional

### 3.1 Introdução

A Inteligência Computacional (IC) é uma área da ciência que busca, através de técnicas inspiradas nos processos presentes na natureza, o desenvolvimento de sistemas computacionais que apresentem aspectos do comportamento humano. Essa estratégia visa à busca de soluções para problemas com elevado nível de dificuldade. Dentre os aspectos desejáveis nessas ferramentas destacam-se a aprendizagem, percepção, raciocínio, evolução e adaptação [D. Gol, 1989]. Diversas são as ferramentas de IC que apresentam essas características, dentre elas destacam-se a Rede neural artificial (RNA), Algoritmo Genético (AG) e Sistema Híbrido (SH).

Uma RNA é uma técnica da Inteligência Computacional que permite usar um hardware físico ou um software de computador para modelar propriedades computacionais análogas ao conhecimento cognitivo do cérebro humano. A sua principal característica é a capacidade de aprender, reconhecer padrões e armazenar relacionamentos entre as entidades alvo do projeto de pesquisa [Fre, s.d.].

Um AG é um algoritmo de aperfeiçoamento matemático baseado nos mecanismos de evolução natural, onde o mais apto sobrevive. Essa ideia é inspirada na proposta de Charles R. Darwin (1809 - 1892), descrito em seu livro *A origem das Espécies* de 1859.

Um AG trabalha a partir da recombinação genética das respostas encontradas em cada geração, assim como elaborado por Gregor Mendel em 1865. Desta forma, em cada geração, a resposta encontrada no espaço de busca será melhor que as soluções iniciais.

Outra técnica de IC é o desenvolvimento de Sistemas Inteligentes Híbridos (SIH) ou Sistemas Híbridos (SH), que são o resultado da combinação de duas ou mais técnicas distintas; sendo que pelo menos uma delas refere-se a uma ferramenta baseada nos princípios dos fundamentos da IC para resolver um determinado problema [Bit, 1998]. A motivação para o desenvolvimento dos sistemas híbridos deve-se ao fato de que algumas técnicas podem ser adequadas para solucionar determinados problemas com características específicas através de estratégias singulares contidas nos diversos equacionamentos presentes.


A combinação de várias técnicas possíveis aproveita as suas vantagens através de cada estratégia presente nas ferramentas, permitindo superar as limitações individuais de cada técnica. Assim, é possível encontrar a solução de um determinado problema [T.B. Lud 1, 2005] [T.B. Lud 2, 2005].

### **3.2 Redes Neurais Artificiais**

Uma RNA pode aproximar e interpolar dados multivariados de maneira rápida e suave e de forma compacta, que poderiam exigir enormes bancos de dados se fosse utilizada uma técnica de programação convencional. As técnicas envolvendo o uso de RNA's são bem aceitas para a resolução de problemas lineares, não lineares, previsão e regressão estatística, reconhecimento de padrões e comportamentos e em outras diversas áreas do conhecimento.

Assim, pela observação do comportamento de resposta das células fotovoltaicas, o uso de RNA's será uma ferramenta propícia para se extrair as características de fabricação e operação das mesmas. Isso se deve a abordagem por meio de RNA's consistir em reconhecer e manipular a informação e aplicar esse conhecimento na resolução de problemas que exigem aprendizado a partir da experiência [Bea, 1990][Zhe, 2010].

A inspiração para a utilização de RNA's é obter uma ferramenta computacional que agisse segundo o funcionamento do cérebro humano. O cérebro humano é o dispositivo mais obscuro estudado pelo homem, sendo ainda o seu funcionamento pouco compreendido [Bea, 1990]. O cérebro humano, assim como seu sistema nervoso, é formado por uma rede de neurônios interligados de acordo com a Figura 3.1. O neurônio é a unidade básica do cérebro responsável pelos fenômenos conhecidos como pensamento, emoção e cognição, além da execução das funções sensoriais, motoras e autônomas, pois possui um elevado poder de processamento das informações recebidas do meio ambiente que o cerca [Was, 1989].



**Fig. 3.1: Representação de um neurônio (célula) humano.**

Cada neurônio compartilha várias características com outras células, principalmente na sua estrutura molecular, mas possui capacidades singulares para receber, processar e transmitir sinais eletroquímicos ao longo das fibras nervosas, que compreendem o sistema de comunicação cerebral [Ste, 1985]. Um neurônio é conectado a vários outros neurônios através dos dendritos e do axônio, formando uma rede sistêmica. Os dendritos recebem os impulsos nervosos de outros neurônios e os conduzem ao núcleo. Essas informações são processadas de acordo com a função específica do neurônio, gerando novos impulsos que são somados. Caso a soma dos impulsos recebidos e processados exceda um determinado limiar característico do neurônio, o axônio transmitirá esse estímulo a outros neurônios através de fenômenos químicos denominados sinapses. A força sináptica da conexão neural permite refletir o nível de excitação ou inibição entre os neurônios adjacentes, capacitando

o cérebro humano ao armazenamento do conhecimento e o consequente aprendizado de acordo com cada função a ser realizada, determinando para cada região específica do cérebro a responsabilidade por sua execução [Bea, 1990].

A RNA é uma técnica computacional que tem como princípio utilizar um modelo matemático inspirado na estrutura neural de organismos inteligentes para poder reproduzir e adquirir conhecimento através da experiência e observação. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento. Já o cérebro de um mamífero pode ter muitos bilhões de neurônios.

*“Um modelo conexionista é uma estrutura de processamento de informações distribuída e paralela. Ela é formada por unidades de processamento, comumente chamadas de nós, neurônios ou células, interconectadas por arcos unidirecionais, também chamados de ligações, conexões ou sinapses. Os nós possuem memória local e podem realizar operações de processamento de informação localizada. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada ramificação possuindo o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula” [Hec, 1998].*

O primeiro modelo formalizado de redes neurais artificiais foi proposto por McCulloch e Pitts, em 1943. Tinha como base o neurônio humano, porém abstraía sua complexidade, assim como a maioria dos modelos conexionistas desenvolvidos posteriormente [Messon, 1990]. Em 1949 HEBB assume que o processo de aprendizagem do conhecimento representado em uma Rede neural artificial é alcançado pelo fortalecimento dos sinais sinápticos presentes nas conexões entre neurônios adjacentes, sempre que esses estiverem excitados. Essa interpretação ficou conhecida como regra HEBB.



Em 1958, Frank Rosenblatt criou o *perceptron*, um modelo cognitivo que consistia em unidades sensoriais conectadas a uma única camada de neurônios de McCulloch e Pitts, com a capacidade de aprender tudo o que pudesse representar dentro do seu universo de operação. Rosenblatt demonstrou que, se fossem adicionadas sinapses (pesos) ajustáveis, as RNA's de McCulloch e Pitts poderiam ser treinadas para classificar padrões em classes linearmente separáveis, convergindo em um número limitado de passos com uma porcentagem de erro máximo tolerável, como apresentado na Figura 3.2 [Messon, 1990].




Fig. 3.2: Representação de um neurônio tipo *perceptron*.

Um novo modelo de neurônio surge no início da década de 60. Widrow e Hoff publicam um artigo no qual especificam o *Adaline*, que é um modelo de neurônio baseado nas redes neurais de McCulloch e Pitts, onde a importância desse modelo está associada à regra de aprendizagem proposta, a regra Delta, que trouxe uma maior possibilidade na resolução de problemas, se comparado a regra HEBB [Messon, 1990].

Em 1969, Minsky e Papert expõem as limitações do modelo de Rosenblatt, provando que tais redes não são capazes de resolver uma ampla classe de problemas devido às restrições de representação como o problema do *ou-exclusivo* (XOR) [Messon, 1990] [Was, 1989]. Isso fez com que somente poucos pesquisadores como Malsburg, Grossberg, Kohonen e Anderson permanecessem concentrando suas atividades na abordagem conexionista, causando uma lacuna tanto na pesquisa e desenvolvimento de redes neurais, como nas suas aplicações para resolução de problemas. Essa situação começou a se reverter na década de 80, devido ao avanço da tecnologia e ao fracasso de outras estratégias, como da escola simbolista na solução de determinados tipos de problemas. As redes neurais artificiais passaram a atrair substancial atenção novamente [Was, 1989].

Em 1982, a introdução do modelo conexionista de Hopfield permitiu esclarecer, pelas suas características computacionais e estabilidade, boa parte das dúvidas até então existentes em relação ao processo dinâmico executado por certas redes neurais. No mesmo ano, Kohonen publicou um artigo descrevendo uma RNA baseada em auto-organização (Mapas auto-organizáveis) e nas características de aprendizado adaptativo do cérebro humano [Messon, 1990]. Hilton e Seynowsky, em 1983, estenderam o modelo de Hopfield com a incorporação de dinâmica estocástica. Este modelo de rede neural passou a ser conhecido como Máquina de Boltzmann, conseguindo grandes sucessos na resolução de diversos tipos de problemas [Was, 1989].

Em 1985, Rumelhart, Hinton e Williams aperfeiçoaram a ideia de *perceptron* diminuindo as restrições de representação existentes por meio da criação do algoritmo *Backpropagation* [Rum, 1986]. Este algoritmo foi aplicado em uma grande variedade de problemas, como na identificação da estrutura de proteínas, hifenização de palavras em inglês, reconhecimento da fala, compressão de imagens e previsão de séries temporais [Messon, 1990]. O sucesso deste algoritmo estimulou o desenvolvimento de muitas pesquisas em RNA e de uma variedade de modelos cognitivos que são aplicados numa diversa gama de problemas.

### 3.2.1 Estrutura da RNA

A Estrutura ou topologia de uma RNA pode ser expressa através de um grafo dirigido com pesos em suas arestas de acordo com a seguinte representação ilustrada na Equação 3.1.

$$G = (V, A, W) \quad (3.1)$$

Onde:

$G$ : Grafo dirigido que representa a RNA.

$V$ : Corresponde a um conjunto de vértices, nós ou neurônios.

$A$ : Corresponde a um conjunto de arestas ou arcos dirigidos.

$W$ : Conjunto de pesos sinápticos para esses arcos.

Cada vértice no grafo representa uma unidade de processamento por meio de uma função de ativação. A RNA pode ser organizada por meio de outras estruturas ou organizações, como camadas, conexões, pesos, neurônios visíveis e neurônios ocultos que permitem aumentar seu poder de processamento. Cada uma dessas estruturas e organizações é apresentada no Apêndice - A.

### **3.2.2 Propriedades das RNA's**

Como o modelo base das redes neurais artificiais são as redes baseadas em neurônios biológicos, a modelagem matemática das RNA's consegue representar um grande número de características observadas no processo cognitivo presente em diversos animais e principalmente no ser humano [Was, 1989]. Entre essas propriedades pode-se destacar o aprendizado pela experiência e pelo erro, a generalização a partir de exemplos e a abstração de características essenciais da informação, descartando os itens irrelevantes para o processo. A seguir são apresentadas as principais propriedades das RNA's.

- **Generalização**

Uma das grandes propriedades das RNA's está no fato que mesmo que uma informação não esteja presente no processo de aprendizagem e treinamento da mesma, é possível reconhecer a informação como verdadeira ou falsa e obter resultados quantitativos e qualitativos de maneira satisfatória dentro dos padrões estabelecidos pela topologia da RNA.

Para isso, a generalização dos resultados obtidos no conjunto de treinamento é de fundamental importância. O que possibilita a obtenção desses dados é a exploração do modelo conexionista que é sensível às variações estimuladas pelo meio ambiente de pesquisa, se faz necessária. Embora essas variações estejam presentes, as RNA's têm como propriedade preservar a identidade e reconhecer um conjunto de características fundamentais da informação. Isso pode ocorrer em informações procedentes dos neurônios de entrada, reconhecendo ruídos e distorções e separando-os da informação correta. A capacidade da rede em se adaptar às novas situações, gerando valores de saída consistentes com os esperados, é vital para a aplicabilidade do modelo em um ambiente do mundo real

[Was, 1989]. Sua aplicação em problemas visa principalmente explorar essa importante característica do modelo conexionista, que é a habilidade em generalizar sobre o domínio do problema [Res 1, 1993].

O desempenho da generalização depende em grande parte da forma como é feita seu treinamento, assim como estão organizados seus dados, e o número de parâmetros livres presentes. Cada um desses parâmetros possui grande influência no seu poder de generalização [Le Cun, 1989].

- Abstração

Alguns modelos de redes neurais artificiais são capazes de abstrair a essência do conjunto de dados a elas apresentados [Was, 1989], permitindo, dessa forma, a classificação ou reconhecimento de padrões incompletos. Essa propriedade é de grande importância na aplicação do domínio do problema, onde o conhecimento das características envolvidas é obscuro.

Assim, um conjunto mínimo de informação é o suficiente para que seja possível extrair as características essenciais do problema de tal maneira que a classificação e o agrupamento de elementos pelo reconhecimento dos padrões mínimos identificáveis sejam possíveis.

- O Aprendizado

O aprendizado é definido como a habilidade de realizar tarefas novas, reconhecer informação ou padrões, identificar características e a chegar a resultados que não podiam ser anteriormente pré-definidos ou estabelecidos, assim como, melhorar a realização de atividades antigas por meio do aperfeiçoamento do processo de realização da atividade relacionada [Carb, 1998].

As RNA's podem modificar seu comportamento em resposta aos estímulos produzidos pelo ambiente, regulando a força da conexão entre neurônios adjacentes pela adaptação tanto dos pesos sinápticos quanto da tendência (*bias*) [Was, 1989]. Essa propriedade de modificação e adaptação dos estímulos do ambiente caracteriza o processo de aprendizagem pelo modelo matemático.

O aprendizado em um modelo de redes neurais artificiais é decorrente do treinamento da rede através de uma estratégia que é construída a partir das características do problema a ser resolvido. Onde, dependendo da forma como é realizada, a apresentação de padrões aos neurônios de entrada é feita por repetidas iterações, o que faz com que ocorra o ajuste tanto dos pesos sinápticos quanto do *bias* para que a rede responda satisfatoriamente aos estímulos recebidos [Messon, 1990].

Assim, o objetivo do treinamento consiste em atribuir aos pesos sinápticos e ao *bias* os valores apropriados, de modo a produzir o conjunto de saídas desejadas ou ao menos consistentes com um intervalo de erro estabelecido [Fre, s.d.]. Desta forma, pode-se dizer que o processo de aprendizado de uma RNA consiste na busca de um espaço de pesos apropriados determinados pela aplicação de alguma regra que defina esta aprendizagem [Messon, 1990].

A grande maioria das regras de treinamento de uma RNA parte do princípio do aprendizado por meio do reforço das conexões sinápticas e podem ser consideradas variantes da Regra de Hebb [Heb, 1949]. Na essência, Hebb propõe que a sinapse, conectando dois neurônios, seja reforçada sempre que ambos os neurônios estiverem ativos. O princípio de aprendizagem da RNA parte então da idéia de se observar situações já conhecidas ou pré-determinadas para encontrar o espaço de pesos e *bias* adequados a solução do problema proposto. Assim, essa estratégia é denominada supervisionada, ou seja, a RNA parte de um conjunto de dados cuja resposta é conhecida para determinar os pesos e *bias* adequados para as demais situações.

Uma RNA que tenha a regra de Hebb como regra de treinamento supervisionado modifica os pesos sinápticos entre as conexões dos neurônios adjacentes proporcionalmente ao produto dos níveis de excitação desses neurônios, conforme Equação 3.2. Uma característica da regra de Hebb é que ela tem a propriedade de localidade. Isto significa que para alterar o valor de uma conexão sináptica, apenas informações locais à sinapse calculada são utilizadas.

$$\Delta w_{ij} = \eta \cdot x_i \cdot y_i \quad (3.2)$$

Onde:

$\Delta w_{ij}$  : Variação do peso  $w_{ij}$ .

$\eta$  : Taxa de aprendizagem.

$x_i$  : Dados de entrada do neurônio i.

$y_i$  : saída de dados do neurônio j.

A regra Delta, também conhecida como Regra de Widrow-Hoff, surgiu como uma evolução da regra de Hebb, onde a modificação dos pesos é feita de acordo com a variação entre a saída desejada e a observada no treinamento também supervisionado [Messon, 1990]. Dessa forma, pode-se observar o erro produzido pela RNA no espaço de pesos atual e sua evolução, no sentido da solução, levando em consideração o erro produzido como apresentado na Equação 3.3.

$$\Delta w_{ij} = \eta(d_i - x_i) \quad (3.3)$$

Onde:

$\Delta w_{ij}$  : Variação do peso  $w_{ij}$ .

$x_i$  : Estado para o neurônio i.

$d_i$  : Saída desejada para a RNA.

$\eta$  : Taxa de aprendizagem.

Isso se deve ao fato do valor da modificação da intensidade da conexão sináptica para as mesmas excitações dos neurônios envolvidos poderem variar com o tempo, ou seja, ao longo das iterações. Desta forma cada modificação da intensidade da conexão sináptica  $\Delta w_{ij}$  pode depender de  $w_{ij}$ , o que será um efeito não linear. No caso da regra Hebb tem-se um sistema bi-linear por apresentar um produto de duas intensidades. Isto ocorre como um efeito de saturação do valor de conexão sináptica. Pode-se também imaginar que a modificação da intensidade da conexão sináptica dependa também de neurônios vizinhos.

Uma característica importante da regra delta é que a mesma minimiza o erro médio quadrático, como apresentado na Equação 3.4.

$$E = \frac{1}{2} \cdot \sum (d_j - y_j)^2 \quad (3.4)$$

Onde:

$E$  : Erro médio quadrático.

$d_j$  : Saída desejada para a RNA.

$y_j$  : Saída do neurônio j.

Este erro é função do valor das conexões e, portanto, para calcular seu mínimo é necessário encontrar os valores que anulam a primeira derivada, como mostrado na Equação 3.5.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_i} \cdot y_i \cdot \partial w_{ij} \quad (3.5)$$

Onde:

$E$  : Erro médio quadrático.

$w_{ij}$  : Peso que liga o neurônio i ao neurônio j.

$y_i$  : Saída do neurônio i.

Portanto, as alterações dos pesos sinápticos ocorrem de forma a minimizar o erro que segue na direção do gradiente descendente, conforme apresentado pela Equação 3.2. Logo a atualização de cada componente do vetor de pesos sinápticos pode ser calculada com base no erro médio quadrático, como apresentado na Equação 3.6.

$$\begin{aligned}
\nabla E(\bar{w}) &= \left[ \frac{\partial E}{\partial w_0}, \dots, \frac{\partial E}{\partial w_n} \right] \\
\bar{w} &\leftarrow \bar{w} + \Delta \bar{w} \\
\Delta \bar{w} &= -\eta \nabla E(\bar{w}) \\
\Delta w_i &= -\eta \frac{\partial E}{\partial w_i} \\
\frac{\partial E}{\partial w_i} &= \frac{\partial}{\partial w_i} \cdot \frac{1}{2} \sum (d_j - y_j)^2 \\
\frac{\partial E}{\partial w_i} &= \frac{1}{2} \sum 2(d_j - y_j) \frac{\partial}{\partial w_i} (d_j - \bar{w} \cdot \bar{x}_j) \\
\frac{\partial E}{\partial w_i} &= \sum (d_j - y_j) \cdot (-x_{ij}) \\
\Delta w_i &= \eta \sum (d_j - y_j) \cdot x_{ij}
\end{aligned} \tag{3.6}$$

Onde:


$E$ : Erro médio quadrático.

$d_j$ : Saída desejada para a RNA.

$y_j$ : Saída do neurônio  $j$ .

$w_i$ : Peso da aresta  $i$ .

A Figura 3.3 apresenta o comportamento esperado para o erro médio quadrático seguindo o gradiente descendente para um espaço composto pelos pesos  $w_0$  e  $w_1$ .



**Fig. 3.3:** Comportamento esperado para a evolução do erro pelo gradiente descendente para os pesos  $w_0$  e  $w_1$ .



A Regra Delta, assim como a regra Hebb, é denominada como biologicamente plausível, pois utilizam apenas informações locais para o cálculo da sinapse para atingir seu aprendizado. O ponto de partida da regra Delta é a generalização da regra de Hebb e efetua uma otimização que pode ser interpretada como o modelo matemático de um mecanismo de seleção.

- Estratégias de Aprendizado

Existem diferentes tipos para o aprendizado da Rede Neural que vão ser selecionados de acordo com as características do problema a ser resolvido pela RNA e por sua topologia. Dentre as estratégias destacam-se [Sil, 1998]:

- a) Treinamento supervisionado: a rede é treinada pela apresentação dos vetores de entrada e seus respectivos vetores de saída, chamados de pares de treinamento. São usados principalmente quando é utilizada a regra Hebb, Regra Delta e o *Backpropagation* (retro propagação do erro) quando a topologia da RNA é acíclica. Pode ser controlada por meio do número de iterações ou erro máximo tolerável.
- b) Treinamento não supervisionado: o treinamento consiste na apresentação apenas dos vetores de entrada, a partir dos quais são extraídas as características desse conjunto de padrões, agrupando-os em classes. O treinamento não supervisionado pode ser observado como um processo autônomo ou auto-organizável. É utilizado principalmente em RNA's cíclicas.
- c) Com reforço: o processo de aprendizagem por reforço consiste em mapear situações (estados do ambiente) para ações (o que fazer) de modo a maximizar um sinal de recompensa numérico. Segundo Sutton e Barto (1998), *“aprendizagem por reforço é definida não pela caracterização de métodos de aprendizagem, mas pela caracterização de um problema de aprendizagem.”* A ideia básica é simplesmente captar os aspectos mais importantes do problema real posto diante de um agente aprendiz interagindo com o ambiente para alcançar uma meta.

Os principais algoritmos utilizados para realizar o processo de aprendizagem da RNA estão presentes no Apêndice - B.

### 3.2.3 Formulação matemática do funcionamento da RNA.

A relevância da utilização de redes neurais artificiais vem do fato de que as mesmas podem ser utilizadas para aproximar funções complexas e não lineares, conforme descrito em [Cyb, 1989]. Nessa referência se demonstra, por meio de teoremas, que combinações lineares finitas de funções sigmoidais, fixas e uni-variadas podem se aproximar uniformemente de qualquer função contínua de  $n$  variáveis reais.

A representatividade das RNA's com uma única camada escondida, com arquitetura *feedforward* e algoritmo de aprendizagem por meio da estratégia *backpropagation*, pode encontrar regiões de decisão no processo de aproximação funcional, cuja sua resposta pode ser arbitrariamente bem aproximada da função que seja objeto de aproximação, por esse tipo de rede.

Segundo [Cyb, 1989] diversas aplicações podem ser modeladas ou representadas através de uma função geral de  $n$ -dimensional de variáveis reais da forma  $x \in R^n$ , que consiste nas combinações lineares finitas da forma da Equação 3.7.

$$G(x) = \sum_{j=1}^N \alpha_j \sigma(y_j^T x + \theta_j) \quad (3.7)$$

Onde:

$y_j$ : Variável real da forma  $R^n$ .

$\alpha_j, \theta_j$ : Variáveis reais.

$y_j^T$ : Variável transposta de  $y$ .

$y_j^T x$ : Representa o produto interno de  $y \cdot x$ .

$\sigma$ : Função uni-variável que é dependente do contexto de aplicação.

As variáveis  $\alpha_j, \theta_j$  e  $y_j$  são fixas e a função  $\sigma$  é também conhecida como função sigmoidal, e representa o foco de operação da RNA. Sua representação é dada pela Equação 3.8, e descrita na Figura A.2 presente no Apêndice - A.


$$\sigma(t) \rightarrow \begin{cases} 1 \Rightarrow t \rightarrow +\infty \\ 0 \Rightarrow t \rightarrow -\infty \end{cases} \quad (3.8)$$

Assim, essa função  $\sigma(t)$  representa uma função sigmoidal que pode ser utilizada na criação dos nós da RNA como função de ativação apresentado na Equação (A.5) presente no Apêndice - A.

Logo, se existe uma função  $G(x)$  da forma da Equação 3.7 que pode representar a resolução de uma determinada aplicação, é possível construir um sistema a partir de uma determinada configuração de RNA baseada na seguinte arquitetura:

- ✓ Modelo de RNA: *feedforward*.
- ✓ Número de camadas escondidas: *Single layer*.
- ✓ Estratégia de treinamento: Supervisionado.
- ✓ Algoritmo de treinamento: *backpropagation*.

Nesse sentido, é necessário verificar a existência de uma função  $G(x)$  que passa realizar a aproximação funcional de um determinado modelo. Para essa verificação será utilizada a modelagem da célula solar pelo circuito elétrico equivalente para o modelo de um diodo, conforme presente na Figura 3.4. A Equação 3.9 apresenta sua modelagem matemática para o modelo do circuito equivalente e está descrito em [Air, 2011] [Rod, 2011] [Rod-2, 2011].



**Fig. 3.4:**Esquema elétrico da célula solar para a aproximação do modelo de um diodo

$$I_l = I_{ph} - I_{sd} \left( e^{\left( \frac{q(V_l + I_l R_s)}{n.K.T} \right)} - 1 \right) - \left[ \frac{V_l + I_l R_s}{R_{sh}} \right] \quad (3.9)$$

Onde:

$I_l$  : É a corrente de terminal (A).

$I_{ph}$  : É a fotocorrente gerada (A).

$I_{sd}$  : Corrente de saturação do diodo (A).

$R_s$  : Resistência em série ( $\Omega$ ).

$R_{sh}$  : Resistência shunt ( $\Omega$ ).

$V_l$  : Tensão nos terminais (V).

A Equação 3.9 é baseada no modelo elétrico para um diodo. Essa Equação pode ser aproximada pela Equação 3.10, na situação de circuito aberto, fazendo  $I_l = 0$ ,  $V_l/n = V_{oc}$  e  $R_{sh}$  possuindo um valor grande, onde  $V_l/R_{sh} \Rightarrow 0$ , conforme descrito em [Pat, 1999] [Mes, 2000]; onde a mesma representa o comportamento de uma célula solar a partir das suas propriedades físicas, como dopagem, comprimento da camada de depleção, velocidade de recombinação superficial, concentração intrínseca, densidade de estados, mobilidade de elétrons e lacunas, tempo de vida dos portadores minoritários e outros fatores que influenciam o comportamento da célula solar, onde a resistência em série não foi considerada nesse modelo.

$$I = I_t - I_0 \left( e^{\left( \frac{q.V}{K.T} \right)} - 1 \right); \quad 0 < V \leq V_{oc} \quad (3.10)$$

Onde:

$I$  : Corrente de curto-circuito (A).

$I_t$  : Fotocorrente total gerada (A).

$I_0$  : Corrente reversa de saturação (A).

$q$  : Carga do elétron (eV).

$V$  : Tensão da célula (V).

$V_{oc}$  : Tensão em circuito aberto (V).

$K$  : Constante de Boltzmann.

$T$  : Temperatura (K).

Essa equação utiliza as características físicas e construtivas da célula solar e representa a aproximação do modelo de circuito elétrico utilizando um diodo. A fotocorrente total  $I_t$  é apresentada nas Equações 3.11, 3.12 e 3.13. A corrente reversa de saturação  $I_0$  é apresentada na Equação 3.14, conforme descrito em [Mat, 2006] [Mat, 2008].

$$I_{t_n} = \frac{q \cdot A \cdot F_{ph} \cdot \alpha \cdot L_n}{\alpha^2 \cdot L_n^2 - 1} \cdot \left[ \frac{S_n \cdot \cosh\left(\frac{W_p}{L_n}\right) + \frac{D_n}{L_n} \cdot \sinh\left(\frac{W_p}{L_n}\right) + (\alpha \cdot D_n - S_n) e^{-\alpha \cdot W_p}}{S_n \cdot \sinh\left(\frac{W_p}{L_n}\right) + \frac{D_n}{L_n} \cdot \cosh\left(\frac{W_p}{L_n}\right)} \right] - \alpha \cdot L_n \quad (3.11)$$

$$I_{t_p} = \frac{q \cdot A \cdot F_{ph} \cdot \alpha \cdot L_p}{\alpha^2 \cdot L_p^2 - 1} \cdot \left[ \frac{S_p \cdot \cosh\left(\frac{W_n}{L_p}\right) + \frac{D_p}{L_p} \cdot \sinh\left(\frac{W_n}{L_p}\right) + (\alpha \cdot L_p - S_p) e^{-\alpha \cdot W_n}}{S_p \cdot \sinh\left(\frac{W_n}{L_p}\right) + \frac{D_p}{L_p} \cdot \cosh\left(\frac{W_n}{L_p}\right)} \right] - \alpha \cdot L_p \quad (3.12)$$

$$I_t = I_{t_n} + I_{t_p} \quad (3.13)$$

$$I_0 = q \cdot A \cdot n_i^2 \cdot \left( \frac{1}{N_a} \cdot \sqrt{\frac{D_n}{\tau_n}} \cdot \coth\left(\frac{W_p}{L_n}\right) + \frac{1}{N_d} \cdot \sqrt{\frac{D_p}{\tau_p}} \cdot \coth\left(\frac{W_n}{L_p}\right) \right) \quad (3.14)$$

$I_{ln}$  representa a fotocorrente gerada no semiconductor tipo N (A),  $I_{lp}$  representa a fotocorrente gerada no semiconductor tipo P (A).  $q$  é a carga do elétron (eV),  $A$  a área da célula ( $m^2$ ),  $\alpha$  é a constante de absorção,  $L_n$  comprimento de difusão de elétrons (nm) e  $L_p$  a de lacunas (nm).  $S_n$  e  $S_p$  representam a velocidade de recombinação superficial no semiconductor tipo N e P ( $cm.s^{-1}$ ) respectivamente,  $W_n$  comprimento da camada de depleção no semiconductor N (nm) e  $W_p$  no semiconductor P (nm).  $D_n$  coeficiente de difusão de elétrons e  $D_p$  de lacunas,  $\tau_n$  e  $\tau_p$  tempo de vida dos portadores minoritários dos elétrons e lacunas respectivamente (s),  $n_i$  concentração intrínseca do semiconductor (átomos. $cm^{-3}$ ),  $N_a$  concentração de dopantes aceitadores (átomos. $cm^{-3}$ ) e  $N_d$  de doadores de elétrons (átomos. $cm^{-3}$ ). A descrição completa o equacionamento do modelo matemático que determina o comportamento elétrico da célula fotovoltaica a partir das suas propriedades físicas é apresentado no Apêndice F.

Considerando a forma da Equação 3.9, representante do comportamento de uma célula solar a partir das suas propriedades físicas, deve-se mostrar a existência de uma possível combinação  $G(x)$  que pode representar a Equação 3.9.

Para demonstrar que  $G(x)$  aproxima funcionalmente de  $I_{sc}$  é necessário que a função  $\sigma$  seja discriminante como apresentado em [Cyb, 1989]. Ou seja,  $\sigma$  deve ter a característica apresentada pela Equação 3.15 para uma medida  $\mu \in M(I_n)$ , onde  $I_n$  denota a unidade  $n$ -dimensional de um hiper-cubo  $[0,1]^n$ ,  $C(I_n)$  representa um espaço de funções contínuas em  $I_n$  e  $M(I_n)$  é definido como sendo o espaço regular de Borel em  $I_n$ .

$$\int_{I_n} \sigma(y^T x + \theta) d\mu(x) = 0 \quad (3.15)$$

Da mesma forma,  $\sigma$  é dito sigmoidal se  $\sigma(t)$  é da forma apresentada pela Equação 3.8. Utilizando essas propriedades para  $\sigma$  é possível fazer uso do teorema apresentado por [Cyb, 1989].

- **Teorema 3.1:** Seja  $\sigma$  uma função contínua e discriminatória, então a soma finita da forma da Equação 3.7 é densa em  $C(I_n)$ . Em outras palavras, dada qualquer  $f \in C(I_n)$  e  $\varepsilon > 0$ , é possível escrever essa soma na forma da Equação 3.16.

$$|G(x) - f(x)| < \varepsilon, \text{ para todo } x \in I_n \quad (3.16)$$

Assim, considere que seja possível escrever uma função  $f(x)$  onde a mesma tenha a seguinte característica:  $f(x) = I_{sc}$ . Como o cálculo de  $I_{sc}$  é obtido pelo cálculo de funções contínuas descritas em [Mat,2006], logo,  $f(x)$  é contínua e logo tem-se que  $f \in C(I_n)$ .

Considere que  $x$  seja formado pelos parâmetros necessários para o cálculo de  $I_{sc}$ , da seguinte forma:  $x = [x_1 = T, x_2 = V_{oc}, x_3 = A, x_4 = L, \dots]$ , onde ( $T$ : Temperatura,  $V_{oc}$ : Tensão em circuito aberto,  $A$ : Área da célula,  $L$ : Iluminação,...), sejam todos os parâmetros necessários para o modelo da célula solar [Mat, 2006]. Como descrito no trabalho de [Mat, 2006]  $I_{sc}$  é determinado a partir dos parâmetros de operação e fabricação da célula solar, e todos esses parâmetros são valores definidos como sendo pertencentes ao conjunto dos números reais. Logo é possível afirmar que  $\forall x_i \in x \rightarrow x_i \in R$ , ou seja,  $x \in R^n$ .

Como por definição,  $G(x)$  é uma função onde  $x \in R^n$ , é possível fazer  $G(T, V_{oc}, A, L, \dots)$ . Pelo Teorema 3.1 é possível então fazer uma soma finita tal que  $|G(x) - f(x)| < \varepsilon$ , para um valor de  $\varepsilon$  arbitrariamente pequeno e valores adequados para  $\alpha_j, \theta_j$  e  $y_j$ .

Logo, sendo  $f(x) = I_{sc}$ , é possível escrever uma soma finita da forma de  $G(x)$  que representa o comportamento da célula solar expressa por  $I_{sc}$  para uma adequada configuração de  $\alpha_j, y_j^T x$  e  $\theta_j$ , onde  $G(x) = I_{sc}$ .

### 3.3 Algoritmos Genéticos

Os Algoritmos Genéticos são inspirados no processo de evolução das espécies biológicas observadas na natureza. Essa inspiração se deve ao fato de que todas as espécies vivas estão sujeitas a se adaptar e evoluir no meio ambiente em que vive para se perpetuar através da herança genética passada aos seus descendentes [Fil, s.d.]. Da mesma forma que as espécies procuram evoluir para se adaptar às condições ambientes, os AG's utilizam a mesma estratégia para procurar num espaço de busca de respostas possíveis, e então evoluírem respostas encontradas para se aproximar ao máximo da solução desejada. Assim, são utilizadas diversas estratégias semelhantes às encontradas na natureza para resolver problemas de busca e otimização [Mit,1996]. Dessa forma, segundo [Fer, 2005], *“os AG's buscam a melhor solução para os problemas de otimização, utilizando um processo iterativo no espaço de busca (soluções) para a resolução do problema apresentado”*.

O processo das respostas inicia-se a partir de uma população inicial que contém um conjunto representativo das soluções para o problema, geradas aleatoriamente. O AG tem como finalidade, então, combinar os representantes desta população através de operadores específicos para a geração de uma nova população que passa a substituir a anterior. A cada nova iteração é gerada uma nova população que apresenta novas e melhores soluções para o problema em questão devido aos operadores genéticos aplicados aos indivíduos presentes na geração anterior e a uma função de avaliação da sua adaptabilidade (proximidade da solução do problema), culminando com a sua convergência.

Esse processo tem como sua principal característica o conceito probabilístico para a resolução do problema, sem a garantia de que a resposta encontrada seja a melhor solução possível para o problema. Porém, sua metodologia heurística garante que o resultado encontrado é uma resposta do problema cuja solução está próxima da melhor solução possível, caracterizando esse processo como estocástico de busca global realizado através da evolução de uma população de soluções [Cos, 2010].

Estes algoritmos começaram a ser estudados por John Holland no começo dos anos 70, onde se deu início a uma pesquisa sobre algoritmos que manipulavam *strings* binárias (0 e 1), a qual ele chamou de cromossomos, uma referência ao cromossomo existente nos seres vivos. Cada cromossomo forma um indivíduo da população, e este por sua vez é



formado por um conjunto de genes individuais que carregam em si um pedaço da informação contida no mesmo. Uma informação para a solução do problema pode ser representada por um único gene, ou esta pode ser constituída de um conjunto de genes para representar uma dada informação, de acordo com a sua complexidade. Assim, um cromossomo pode conter diversas informações que combinadas resultam numa solução válida para o problema proposto.

Seus algoritmos realizavam a evolução simulada destas populações, resolvendo de forma eficiente o problema de encontrar bons resultados através da manipulação do material contido nos mesmo. Existem diversas técnicas que podem ser utilizadas para codificar cada gene dos cromossomos que varia conforme o tipo e as especificidades do problema, como:

- a) Uma codificação binária, sendo que cada bit ou um conjunto de bits representa uma determinada característica presente na informação representada pelo cromossomo. Esse cromossomo é uma possível solução para o problema a ser solucionado pelo AG. Sua representação é apresentada na Figura 3.5.

1	0	1	1	0	1	0	0	0	1
---	---	---	---	---	---	---	---	---	---

**Fig. 3.5:Cromossomo com codificação de gene utilizando a codificação binária**

- b) Uma cadeia de strings que combinadas armazenam a informação necessária. A Figura 3.6 apresenta a codificação do cromossomo.

A	D	F	E	G	A	A	B	C	A
---	---	---	---	---	---	---	---	---	---

(a)

ASA	CASA	FAMA	LAMA	GLORIA
-----	------	------	------	--------

(b)

**Fig. 3.6:Cromossomo com codificação de gene por string simples (a) e por string composta (b)**

- c) Um gene contendo uma variável numérica contínua ou discreta que armazena o seu próprio valor real para codificar suas características e é apresentado na Figura 3.7.

0,732	0,575	0,200	0,500	0,300	1,000	0,666	0,600	0,000	0,435	0,237	0,600	0,270
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------

**Fig. 3.7: Cromossomo com codificação de gene por valor real**

Cada indivíduo da população passa por uma função de avaliação chamada de função *fitness*. Essa função toma como entrada um cromossomo e retorna um parâmetro, geralmente um valor associado à qualidade do mesmo referente à resposta para a solução do problema.

A descrição dos operadores genéticos encontra-se no Apêndice A.

### 3.3.1 Técnicas de aptidão

O algoritmo genético possui, na sua implementação, uma ferramenta para a análise da qualidade do cromossomo. Essa análise é realizada pela função de aptidão para a solução do problema. Assim, cada indivíduo é avaliado de acordo com sua aptidão em relação ao meio ambiente que o cerca. Os principais métodos são:

- *Fitness*: Função de Avaliação – Utiliza-se uma função ou parâmetro de avaliação de forma que cada cromossomo do indivíduo seja processado de forma a gerar uma nota para o mesmo. Dessa forma a função *fitness* deve representar a forma de se chegar a uma solução ótima. Geralmente tem-se a forma de acordo com a Equação 3.17.

$$A_i = f_A(i) \quad (3.17)$$

Onde:

$A_i$  : Resultado da função de avaliação do indivíduo  $i$ .

$f_A(i)$  : Função *Fitness*.

- *Windowing*: Aptidão relativa – Consiste na atribuição da nota de aptidão para cada indivíduo relativo à população geral, ou seja, busca-se observar se a população como um todo está evoluindo e qual o nível de desenvolvimento e não apenas do melhor indivíduo. O cálculo de *Windowing* é representado pela Equação 3.18.

$$\begin{aligned}
A &= \min(f_A(i)) \\
A_i &= f_A(i) \\
A_i &= A_i - A
\end{aligned}
\tag{3.18}$$

Onde:

$A$ : O menor *fitness* medido para a população.

$A_i$ : *Fitness* do indivíduo  $i$ .

$f_A(i)$ : Função *Fitness*.

- Normalização Linear: Consiste em normalizar os resultados da avaliação recebida pelos indivíduos gerados.

A função de avaliação do algoritmo genético pode ser considerada como a responsável por permitir a evolução das respostas para solução do problema e classificar a melhor resposta. Isso se deve ao fato da função de seleção ser dependente dos resultados atribuídos pela mesma. Sua significância também é destacada devido ao fato de que ela é dependente do problema que o AG se propõe a resolver, enquanto os demais mecanismos do AG (seleção, cruzamento e mutação) são apenas adaptados para trabalhar com aquele cenário. O algoritmo de execução do Algoritmo Genético está apresentado no Apêndice - C.

### 3.3.2 Resolução por método Heurístico

A definição de heurística pode ser entendida como a capacidade que um sistema tem em resolver problemas a partir de inovações imediatas e positivas das soluções encontradas. Apesar da capacidade heurística ser uma propriedade inerente dos seres humanos, a transposição dessa técnica para sistemas computacionais vem se mostrando bastante prática na resolução de aplicações nas mais diversas áreas.

Assim uma heurística pode ser tratada como a ciência do descobrimento como afirmou seu criador George Pólya (1887-1985) em seu livro *How solve it* (1957), onde estratégias, regras, silogismo e conclusões heurísticas podem ser utilizadas para a resolução

de uma infinidade de problemas. Quatro estratégias principais são abordadas para a resolução de problemas:

- Para um problema de grande complexidade, onde a compreensão do todo é difícil, um esquema resumido do problema pode ajudar a solucioná-lo.
- Se a solução do problema não puder ser encontrada, a utilização de um caminho partindo de uma solução arbitrária para o problema pode fornecer a solução desejada. Esse é o princípio da engenharia reversa.
- Para um problema abstrato, a exemplificação do mesmo num exemplo real pode ajudar a solucionar o problema.
- Para a solução de um problema, encontrar a resolução do caso geral e depois encontrar a solução do caso específico. Essa estratégia é conhecida como paradoxo do Inventor.

Baseada nessas estratégias, a ANSI/IEEE 100-1984 (*American National Standards Institute* - Instituto Nacional Americano de Padronização) / (*Institute of Electrical and Electronic Engineers* - Instituto de Engenheiros Eletricistas e Eletrônicos) definem heurística como: “*Um método ou algoritmo exploratório para a definição de problemas em que as soluções são descobertas pela avaliação do progresso obtido na busca de um resultado final*”. Ou seja, embora os algoritmos sejam utilizados para o processamento e a computação dos resultados, o progresso ou evolução no sentido da solução do problema é baseado única e exclusivamente na avaliação empírica do resultado.

Embora uma heurística não assegure a melhor solução para o problema, pois não é possível fazer uma prova matemática ou lógica do resultado encontrado, ela possui como característica encontrar soluções válidas de acordo com o domínio de aplicação. Assim como os AG's utilizam intrinsecamente o método heurístico para a resolução do problema de busca num espaço amostral, e o mesmo se utiliza das quatro estratégias supracitadas para a resolução do problema, logo existe a garantia que o mesmo encontrará uma solução válida. Além de se ter essa garantia faz-se necessária uma avaliação empírica para validar os resultados finais obtidos.

### 3.4 Sistemas Híbridos

O conceito de Sistema Híbrido, Sistema Híbrido Inteligente ou de Método Híbrido de Aquisição de Conhecimentos é uma técnica da Inteligência Computacional que busca reunir numa única aplicação duas ou mais ferramentas que exploram a solução de um determinado problema de forma diferente, porém mantendo uma sinergia entre os mesmos. Apesar dos SH serem mais complexos e difíceis de serem implementados, devido ao fato de serem compostos por múltiplos módulos com ferramentas computacionais distintas, e da necessidade de contínua interação entre os módulos, esta técnica de sistemas tem sido muito estudada e aplicada em diversos problemas do mundo real [Bra, s.d.]. Isso se deve ao fato de apresentar diversas vantagens sobre outras técnicas. Podem se destacar as seguintes vantagens dos sistemas híbridos:

- A integração de várias técnicas complementares permite que uma complete as deficiências da outra de forma a obter um melhor desempenho [Pag, 2003][Aze, 1999].
- Ao utilizar diferentes técnicas de aquisição, manipulação e de representação de conhecimentos, amplia-se a capacidade do sistema de adquirir e tratar novas informações, permitindo que o SH agregue capacidades e habilidades que não são limitadas pelas imposições e restrições de um único método.
- Permite que algumas tarefas muito complexas possam ser abordadas e decompostas em subproblemas que podem ser tratados individualmente, chegando-se a uma solução global do problema [Bra, s.d.].
- Permite também o emprego de processamento em paralelo de informações pelos diferentes módulos, possibilitando o desenvolvimento de sistemas com um maior desempenho, mais robustos, e com uma maior tolerância à falhas.

A utilização de Sistemas Híbridos tem maior capacidade de reprodução do comportamento inteligente humano, que se caracterizam principalmente por:

- Capacidade de empregar múltiplos métodos para a solução de problemas, usando diferentes técnicas, como por exemplo, soluções baseadas em experiências passadas, em conhecimentos teóricos adquiridos, conhecimento

empírico etc. Aliado ao fato da adoção de diferentes métodos de raciocínio, como por inferência, probabilidades, dedução, analogia, etc.

Os sistemas inteligentes procuram através da integração de diferentes métodos automáticos emularem a inteligência humana na solução de problemas. Integrar diferentes tipos de representação de conhecimentos, como exemplos de ocorrência (casos típicos), contra exemplos (casos atípicos), regras, predicados lógicos, probabilidades etc. Combinar a representação da informação em múltiplos módulos para ter um sistema mais robusto, que seja possível tratar contradições e conflitos cognitivos entre os seus diferentes módulos. Alguns exemplos de integração de SH são apresentados no Apêndice - D.

Com base na fundamentação teórica apresentada e embasada no Teorema 3.1 e nas propriedades da resolução por métodos heurísticos, é proposta uma técnica para a geração da curva I-V a partir de um conjunto mínimo de parâmetros construtivos da célula solar, e a estimação das propriedades físicas da mesma. A metodologia de utilização dessa técnica baseada em ferramentas de IC é apresentada nos capítulos 4 e 5. No capítulo seguinte é utilizada uma abordagem de tratamento dos dados que serão utilizados pelo modelo proposto.

# Capítulo 4

## **Preparação dos dados para serem utilizados com as ferramentas de IC**

### **4.1 Introdução**

A utilização das técnicas de IC, para a estimação das características físicas das células solares é uma estratégia que vai permitir obter resultados equivalentes ao modelo determinístico, assim como também estimar as propriedades físicas da célula solar a partir da leitura dos componentes da curva I-V. Essas características físicas são determinantes para a verificação de inúmeros quesitos que se queira observar durante a operação da célula solar, como sua eficiência, utilização na composição de um painel solar, determinação de resistências e capacitâncias associadas etc [Kin, 1997].

A técnica permite a utilização de dados provenientes de leituras de células solares cuja sua composição de fabricação seja conhecida ou a utilização de dados dos modelos determinísticos já existentes, que realizam a modelagem computacional das células solares, como modelagem numérica de portadores livres [Pan, 2000][Gur, 1999], PC-1D [Abd, 2008] [Clu, 1997], AFORS-HET [L. Zhao, 2008][Stan, s.d.], AMPS-1D [Her, 2010], PMCCF [Mat, 2006][Mat, 2008] (Programa de Modelagem Computacional de Células Fotovoltaicas) etc. Isso porque os dados fornecidos por esses programas podem ser utilizados como apoio durante o processo de treinamento do modelo proposto.

Neste estudo foram utilizados os programas PMCCF [Mat, 2006][Mat, 2008] [Mat, 2007] desenvolvido na Universidade Federal de Uberlândia e o software PC-1D versão 5.9 [Clu, 1997] como base de dados para o treinamento e validação dos resultados utilizados nas ferramentas de IC.

A técnica consiste em utilizar diversas ferramentas de IC como RNAs, algoritmos genéticos e sistemas híbridos para estimar diversas propriedades das células solares presentes nos modelos existentes. Os programas para modelagem das células solares PMCCF e o PC-1D utilizam estratégias distintas para estimar os resultados de funcionamento da célula solar. Cada modelo exige, por tanto, uma estratégia singular para estimar os dados de fabricação presentes no modelo.

Para a modelagem do PMCCF os melhores resultados foram obtidos a partir da utilização do sistema híbrido (SH). O SH utilizado é composto por um algoritmo genético que tendo como função de avaliação uma RNA treinada a partir dos dados fornecidos pelo modelo determinístico elaborado no PMCCF. Já para a modelagem do PC-1D, os melhores resultados foram obtidos através da utilização de uma RNA a partir dos dados da curva I-V presente nesse modelo.

## **4.2 Preparação dos dados do modelo PMCCF**

O PMCCF utiliza uma grande gama de variáveis necessárias para o modelo determinístico, a ideia inicial é reduzir esse conjunto para um patamar que seja possível mensurar durante medidas e análises em laboratório. Uma vez treinada, a RNA permitirá calcular o *fitness* dos indivíduos gerados pelo AG, de acordo com as características de leitura e fabricação encontradas. Assim, o AG tem como responsabilidade determinar a probabilidade da célula solar ser composta por determinados tipos de dopantes e suas respectivas concentrações. As Equações que regem o funcionamento do PMCCF estão presentes no apêndice F.

A escolha das variáveis de saída está intimamente ligada a qual objetivo deseja-se alcançar com a execução da RNA [Villa, 2010]. Da mesma forma, é necessário favorecer a utilização de variáveis de mesma grandeza de escala, de forma a minimizar o esforço computacional no cálculo da solução e também promover a convergência da resposta desejada. Neste projeto optou-se por determinar as curvas características da célula fotovoltaica, tanto em termos de tensão e corrente como de tensão e potência, que poderiam ser rapidamente verificadas, tanto em comparação com o modelo determinístico como pela medição direta de uma célula solar com as características de fabricação determinadas.



Para se obter as curvas de tensão e corrente da célula fotovoltaica alguns parâmetros são necessários. São eles: a corrente de curto-circuito, a tensão em circuito aberto, e a corrente reversa de saturação. Com esses valores determinados é possível utilizar a equação característica da célula fotovoltaica apresentada na Equação 3.10 para calcular os pontos pertencentes à curva característica da célula fotovoltaica I-V.

Para se obter a curva de tensão e potência da célula fotovoltaica, calcula-se o valor da potência a partir dos pontos da curva I-V, apresentando assim, as curvas necessárias para demonstrar o comportamento da célula fotovoltaica a partir das suas propriedades construtivas e de operação. É importante observar que o valor da corrente reversa de saturação não está na mesma escala de grandeza, tanto da corrente nominal da célula fotovoltaica como também da tensão gerada pela mesma. Ou seja, enquanto para uma determinada configuração de fabricação e operação de uma célula solar um valor esperado para a corrente de curto circuito esteja por volta de 2,7 Ampères e a tensão em circuito aberto esteja ao redor de 0,560 volts, a corrente reversa de saturação esperada estaria por volta de  $7,8 \times 10^{-16}$  Ampères; o que sem dúvida, complica o processamento da RNA para determinar uma solução adequada devido à dimensionalidade da corrente reversa de saturação em relação, tanto da corrente de curto-circuito quanto da tensão em circuito aberto.

Por outro lado, uma vez determinada a corrente de curto-circuito, a tensão em circuito aberto e um ponto qualquer da curva, como o ponto de potência máxima (corrente e tensão no ponto de potência máxima); é possível, novamente utilizando a Equação 3.10, calcular a corrente reversa de saturação e dispensar a RNA do cálculo da mesma. Como a corrente e a tensão no ponto de potência máxima estão na mesma faixa de grandeza, e consequentemente com a mesma dimensionalidade, é mais indicado o cálculo desses dois parâmetros para a resolução completa do sistema. Assim, as variáveis escolhidas para serem calculadas pela RNA são a corrente de curto-circuito ( $I_{sc}$ ), a tensão em circuito aberto ( $V_{oc}$ ) e a corrente no ponto de potência máxima ( $I_{pmax}$ ) e a tensão no ponto de potência máxima ( $V_{pmax}$ ).

#### 4.2.1 Determinação das variáveis de entrada PMCCF

A Determinação das variáveis de entrada numa RNA é de fundamental importância para evitar que dados de baixa relevância sejam inseridos no vetor de treinamento. Esses dados podem dificultar a convergência da RNA para a solução do problema, além de aumentar consideravelmente o esforço computacional para se atingir o objetivo [Bae, 2009].

Assim, é necessário realizar um tratamento no conjunto dos dados de entrada para avaliar se os mesmos possuem relevância para a solução do problema e não apresentam redundâncias. Esse tratamento parte de duas abordagens sobre o conjunto de dados. O primeiro grupo de técnicas tem por objetivo refutar dados de pouca relevância, enquanto o segundo parte da aplicação de uma transformação nas variáveis de entrada (transformação linear ou não) com o objetivo de reduzir o número de variáveis necessárias.

O resultado da aplicação dessas técnicas é um novo conjunto de dados (subconjunto do original), cujos padrões possuem um menor número de características, porém com reduzida perda de informação em relação ao conjunto de dados originais. Como ferramentas do primeiro conjunto de técnicas, serão utilizadas a análise da entropia e a análise de correlação. Já para o segundo grupo de técnicas será utilizada a análise dos componentes principais (*Principal Component Analysis* - PCA). O conjunto de variáveis restantes será utilizado na RNA após passar por uma normalização para se adequar à função de ativação utilizada [Lud, 2007].

##### a) Análise da Entropia e da Correlação

O conjunto de dados originais é composto por 29 itens de entrada baseados no modelo determinístico presente em [Mat, 2006] e implementado no programa PMCCF. Para se avaliar a relevância desses parâmetros para a utilização na RNA, o uso da análise da entropia e da análise da correlação é de fundamental importância.

A análise da entropia de uma variável vai permitir mensurar a quantidade de informação que a mesma é capaz de armazenar referente às características do padrão.

Portanto, as variáveis com um baixo valor de entropia, menor que o limiar estabelecido pelo projeto, não devem ser utilizadas no vetor de entrada de dados [Pres, 1992].

Para que seja possível o cálculo da entropia das variáveis a serem utilizadas pela RNA, é necessário estabelecer para cada característica uma variável aleatória discreta. Isso é possível porque cada característica de entrada de uma célula fotovoltaica está representada por uma variável discreta  $x_i$ . Assim, para cada variável discreta, é necessário calcular a probabilidade de um evento ocorrer. Assumindo que a célula solar seja fabricada a partir do elemento silício (Si), as probabilidades de cada variável aleatória serão apresentadas na Tabela 4.1.

Um conjunto aleatório de dados compostos por 3000 simulações formam o espaço amostral do experimento, a partir do modelo PMCCF. Para cada variável foram agrupados os valores típicos de acordo com o modelo, respeitando-se as faixas de limite para cada uma, de forma a não comprometer a interpretação física do modelo. Cada variável aleatória, que representa uma característica da célula fotovoltaica, é dita equiprovável para seus valores. O índice  $i$  representa um tipo de variável aleatória e o valor  $p_i$  representa a probabilidade de se ocorrer um evento. A probabilidade de ocorrência de um determinado valor para uma variável aleatória foi obtido a partir do cálculo da frequência relativa dentro do espaço amostral, conforme apresentado na Equação 4.1.

$$F_r = \frac{N_v}{N_s} \quad (4.1)$$

Onde:

$F_r$ : Frequência relativa.

$N_v$ : Número de vezes que um determinado valor aparece na simulação.

$N_s$ : Número de simulações realizadas.

Para calcular a entropia de uma variável é necessário calcular a quantidade de informação revelada pela mesma  $I(x_i)$ . Esta quantidade de informação está relacionada à raridade do evento, ou seja, quanto mais esperado é um evento menos informação é obtida após a sua observação. Por outro lado, um evento raro é cercado de circunstâncias muito específicas e reveladoras. Ou seja, quando um evento raro acontece muita informação nova

pode ser obtida pela observação das propriedades e métodos que proporcionaram a ocorrência do evento. A quantidade de informação é definida pela Equação 4.2 [Pres, 1992].

$$I(x_i) = \log\left(\frac{1}{p_i}\right) \quad (4.2)$$

Onde:

$I(x_i)$ : Quantidade de informação apresentada pela variável  $x_i$ .

$p_i$ : Probabilidade de ocorrer um evento de  $x_i$ .

A entropia é o valor médio da quantidade de informação  $I(x_i)$  que uma variável aleatória pode revelar, ou seja, o valor médio de  $I(x_i)$  sobre os N possíveis valores da variável aleatória. Sua definição é apresentada na Equação 4.3.

$$H(x) = E[I(x_i)] = \sum -\log(p_i) \cdot p_i \quad (4.3)$$

Onde:

$H(x)$ : Valor da entropia da variável  $x$ .

$E[I(x_i)]$ : Esperança de ocorrer um evento em  $x_i$ .

$I(x_i)$ : Quantidade de informação apresentada pela variável  $x_i$ .

$p_i$ : Probabilidade de ocorrer um evento de  $x_i$ .

Assim, levando-se em análise a entropia das variáveis, serão selecionadas as que possuírem entropia maior que zero, ou seja, que revelem alguma informação. Quanto maior o valor da entropia mais significativa é a informação presente na variável. Porém, mesmo uma variável com pequeno valor de entropia pode transportar informação essencial para a execução da RNA.

A segunda análise que será realizada sobre os dados de entrada a serem utilizados na RNA é referente à sua relação com a resposta esperada. Para isso a análise do coeficiente de correlação é uma importante ferramenta.

**Tabela 4.1: Variáveis da célula solar baseadas no modelo PMCCF – Cálculo da Entropia**

Característica	Variável Aleatória $x_i$	Ocorrências	$p_i$	Entropia $H(x)$
Eletronegatividade	1	1	1	0
Energia GAP	2	12	0,08334	1,077
Concentração Intrínseca	3	12	0,08334	1,077
Massa Efetiva do Elétron	4	1	1	0
Massa Efetiva da Lacuna	5	1	1	0
Constante Dielétrica do material	6	1	1	0
Momento do Elétron	7	1	1	0
Mobilidade do Elétron	8	1	1	0
Mobilidade da Lacuna	9	1	1	0
Estrutura do Cristal	10	1	1	0
Tipo de GAP	11	1	1	0
Constante da Rede	12	1	1	0
Tempo de vida portador Minoritário	13	1	1	0
Índice de Refração	14	1	1	0
Constante de difusão dos Elétrons	15	1	1	0
Constante de difusão das Lacunas	16	1	1	0
Densidade de Estados c. Condução	17	1	1	0
Densidade de Estados c. Valência	18	1	1	0
Elemento dopante tipo N	19	3	0,3334	0,477
Concentração do elemento doador	20	40	0,025	1,602
Energia do elemento dopante tipo N	21	3	0,025	1,602
Elemento dopante tipo P	22	4	0,25	0,602
Concentração do elemento aceitador	23	40	0,025	1,602
Energia do elemento dopante tipo P	24	4	0,25	0,602
Irradiância	25	13660	$7,3 \times 10^{-5}$	4,135
Temperatura	26	1100	$9,1 \times 10^{-4}$	3,041
Espessura do semicondutor N	27	1	1	0
Espessura do semicondutor P	28	1	1	0
Área da célula solar	29	3000	$3,3 \times 10^{-4}$	3,477

O coeficiente de correlação irá medir o grau e a direção dessa correlação entre as variáveis de entrada e saída, buscando verificar a qualidade de um ajuste linear dos dados. Esse coeficiente retorna um valor entre 1 e -1 que pode ser interpretado da seguinte maneira:

- **Coefficiente de Correlação = 1:** Significa uma correlação linear perfeita positiva entre a variável de entrada e a variável de saída.
- **Coefficiente de Correlação = 0:** Significa que a variável de saída não possui uma dependência linear direta com a variável de entrada. No entanto, pode existir uma relação não linear entre as duas. Nesse caso seria necessária outra ferramenta para verificar se as variáveis não possuem nenhum tipo de correlação.
- **Coefficiente de Correlação = -1:** significa uma correlação linear perfeita negativa entre as variáveis de entrada e saída, ou seja, seus valores são inversamente proporcionais.

O cálculo do coeficiente de correlação é apresentado na Equação 4.4 [Lud, 2007]. Essa Equação retorna o valor correspondente ao tipo de linearidade encontrado entre as variáveis de entrada e saída. Assim, pode-se classificar a força e o sentido da correlação. Uma correlação é denominada forte se o valor encontrado pela Equação 4.4 estiver compreendido no intervalo de  $0,7 \leq r \leq 1,0$  ou  $-1,0 \leq r \leq -0,7$ . Caso o valor encontrado estiver no intervalo  $0,4 \leq r < 0,7$  ou  $-0,7 < r \leq -0,4$  o tipo de correlação é denominada moderada. E, por fim, se o resultado da equação estiver no intervalo  $0 < r < 0,4$  ou  $-0,4 < r < 0$  a correlação é denominada fraca. Já o sentido da correlação é determinado pelo sinal de  $r$ . Se  $r$  positivo, a correlação é direta, se negativo é denominado inversa.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \cdot \sqrt{\sum (y_i - \bar{y})^2}} \quad (4.4)$$

Onde:

$r$ : Coeficiente de correlação da variável  $x$  para a variável  $y$ .

$x_i$ : Valor da variável aleatória de entrada.

$\bar{x}$ : Valor médio da variável aleatória  $x$ .

$y_i$ : Valor de saída a partir das variáveis de entrada  $x_i$ .

$\bar{y}$ : Valor médio da variável aleatória  $y$ .

Do modelo determinístico baseados no programa PMCCF são retirados os dados simulados para determinar o valor da correlação conforme apresentado na Tabela 4.2.

**Tabela 4.2: variáveis da célula solar baseadas no modelo determinístico - Correlação**

Característica	Variável Aleatória $x_i$	Correlação Voc	Correlação Vmax	Correlação Isc	Correlação I <sub>max</sub>
Energia GAP	2	-0,309	0,201	0,167	-0,286
Corrente Intrínseca	3	0,191	-0,241	-0,208	0,168
Elemento dopante N	19	0,192	0,078	0,102	0,182
Concentração dopante N	20	0,102	0,174	0,168	0,108
Energia dopante N	21	0,192	0,078	0,102	0,182
Elemento dopante P	22	0,373	-0,056	-0,018	0,351
Concentração dopante P	23	0,101	0,061	0,063	0,101
Energia dopante P	24	0,373	-0,056	-0,018	0,351
Irradiância	25	1,000	0,706	0,721	0,999
Temperatura	26	-0,052	-0,318	-0,280	-0,075
Área da célula	29	0,053	0,122	0,741	1,000

Para que uma variável seja considerada candidata a ser utilizada na RNA deve ocorrer pelo menos uma correlação (direta ou inversa) com uma das variáveis de saída, como foi o caso das variáveis presentes na Tabela 4.2. Logo, não é necessário fazer outro tipo de análise nas variáveis que apresentaram uma correlação não linear com as variáveis de saída. Mesmo que somente existam correlações consideradas fracas entre as variáveis de entrada e as variáveis de saída, a contribuição de cada variável para a solução do problema é de grande relevância, principalmente se considerada a quantidade de informação transportada pelas mesmas [Lud, 2007].

## **b) Análise dos Componentes Principais - PCA**

O método de análise dos componentes principais consiste na eliminação da covariância das coordenadas do vetor de entrada por meio de uma mudança de base. A existência de covariância implica numa informação redundante e desnecessária que pode prejudicar o processamento da RNA, tanto em termos de complexidade computacional como no processo de convergência do resultado. A troca de base das coordenadas do vetor de entrada se dá por meio da utilização dos autovalores da matriz de covariância, permitindo assim, a diagonalização dessa matriz, o que elimina a covariância existente

entre as coordenadas do vetor de entrada (variáveis aleatórias candidatas) [Lud, 2007][Str, 1988].

Com a transformação da matriz de covariância para a nova base, um menor número de variáveis é necessário para representar a informação, formando assim, um novo vetor de entrada de dados que é utilizado no processamento da RNA. Esse novo vetor é um subconjunto do vetor original de dados e possui a propriedade de preservar as características e o poder de representação da informação da mesma maneira do vetor inicial.

O vetor na nova base apresenta algumas coordenadas com grande variância, isto é, a informação contida em cada variável é relevante e não redundante. As coordenadas com pequena variância (próximo de zero) não são consideradas, isso porque a baixa variância implica que a informação está compartilhada entre as variáveis, fazendo com que características repetidas estejam presentes nessas variáveis. Logo uma variável aleatória com baixa variância não revela muita informação se comparada com as demais variáveis pertencentes ao conjunto.

O método da análise dos componentes principais inicia-se pela construção da matriz de covariância, onde cada posição da matriz representa a covariância de duas variáveis aleatórias  $x_i$ . A construção da matriz de covariância se dá pela Equação 4.5 e está presente na Tabela 4.3.

$$s^2(x_i, x_j) = \sum x_i[n]x_j[n] - \frac{\sum x_i[n]\sum x_j[n]}{N} \quad (4.5)$$

Onde:

$s^2(x_i, x_j)$ : covariância entre as variáveis  $x_i$  e  $x_j$ , onde  $i \neq j$ .

$x_i$ : Valor da variável aleatória de entrada na posição  $i$ .

$x_j$ : Valor da variável aleatória de entrada na posição  $j$ .

$N$ : Número de termos do vetor de entrada.



Tabela 4.3: Tabela que representa a matriz de covariância

$x_i / x_j$	2	3	19	20	21	22	23	24	25	26	29
2	$1,13 \times 10^{-4}$	$-5,17 \times 10^2$	$4,50 \times 10^{-3}$	$9,00 \times 10^{-3}$	$-1,13 \times 10^{-4}$	$5,20 \times 10^{-3}$	$9,00 \times 10^{-3}$	$3,00 \times 10^{-4}$	$4,50 \times 10^0$	$1,79 \times 10^{-1}$	$5,49 \times 10^{-1}$
3	$-5,17 \times 10^2$	$2,34 \times 10^9$	$-2,15 \times 10^4$	$-4,30 \times 10^4$	$5,18 \times 10^2$	$-2,46 \times 10^4$	$-4,30 \times 10^4$	$-1,53 \times 10^4$	$-2,15 \times 10^7$	$-8,60 \times 10^5$	$-2,76 \times 10^6$
19	$4,50 \times 10^{-3}$	$-2,16 \times 10^{-4}$	$5,00 \times 10^{-1}$	$1,00 \times 10^0$	$-4,50 \times 10^{-3}$	$4,99 \times 10^{-1}$	$1,00 \times 10^0$	$5,75 \times 10^{-2}$	$5,00 \times 10^2$	$2,00 \times 10^1$	$1,00 \times 10^2$
20	$9,00 \times 10^{-3}$	$-4,30 \times 10^4$	$1,00 \times 10^0$	$2,00 \times 10^0$	$-8,90 \times 10^{-3}$	$1,00 \times 10^0$	$2,00 \times 10^0$	$1,15 \times 10^{-1}$	$1,00 \times 10^3$	$4,00 \times 10^1$	$2,00 \times 10^2$
21	$-1,13 \times 10^{-4}$	$5,17 \times 10^2$	$-4,50 \times 10^{-3}$	$-8,90 \times 10^{-3}$	$1,14 \times 10^{-4}$	$-5,19 \times 10^{-3}$	$8,90 \times 10^{-3}$	$-3,03 \times 10^{-4}$	$-4,50 \times 10^0$	$-1,79 \times 10^{-1}$	$-5,50 \times 10^{-1}$
22	$5,20 \times 10^{-3}$	$-2,46 \times 10^4$	$4,99 \times 10^{-1}$	$1,00 \times 10^0$	$-5,19 \times 10^{-3}$	$5,06 \times 10^{-1}$	$1,00 \times 10^0$	$5,55 \times 10^{-2}$	$5,00 \times 10^2$	$2,00 \times 10^1$	$9,67 \times 10^1$
23	$9,00 \times 10^{-3}$	$-4,30 \times 10^4$	$1,00 \times 10^0$	$2,00 \times 10^0$	$-8,90 \times 10^{-3}$	$1,00 \times 10^0$	$2,00 \times 10^0$	$1,15 \times 10^{-1}$	$1,00 \times 10^3$	$4,00 \times 10^1$	$2,00 \times 10^2$
24	$3,00 \times 10^{-4}$	$-1,53 \times 10^3$	$5,74 \times 10^{-2}$	$1,15 \times 10^{-1}$	$-3,03 \times 10^{-4}$	$5,54 \times 10^{-2}$	$1,15 \times 10^{-1}$	$7,23 \times 10^{-3}$	$5,75 \times 10^1$	$2,30 \times 10^0$	$1,25 \times 10^1$
25	$4,50 \times 10^0$	$-2,15 \times 10^5$	$5,00 \times 10^2$	$1,00 \times 10^3$	$-4,50 \times 10^0$	$5,00 \times 10^2$	$1,00 \times 10^3$	$5,75 \times 10^1$	$5,00 \times 10^5$	$2,00 \times 10^4$	$1,00 \times 10^5$
26	$1,80 \times 10^{-1}$	$-8,60 \times 10^5$	$2,00 \times 10^1$	$4,00 \times 10^1$	$-1,80 \times 10^1$	$2,00 \times 10^1$	$4,00 \times 10^1$	$2,30 \times 10^0$	$2,00 \times 10^4$	$8,00 \times 10^2$	$4,00 \times 10^3$
29	$5,49 \times 10^{-1}$	$2,76 \times 10^6$	$1,00 \times 10^2$	$2,00 \times 10^2$	$-5,50 \times 10^{-1}$	$9,67 \times 10^1$	$2,00 \times 10^2$	$1,25 \times 10^1$	$1,00 \times 10^5$	$4,00 \times 10^3$	$2,17 \times 10^4$

Com a matriz de covariância obtida é possível determinar seus autovalores para verificar quais são os elementos das variáveis mais importantes para o processamento da RNA. A matriz de covariância possui a propriedade da simetria, o que permite que os autovalores dessa matriz sejam obtidos pelo método de diagonalização Jacobiana [Hof, 2001], [D. V. Grif, 2006].

#### **a) Método da diagonalização Jacobiana**

A diagonalização Jacobiana consiste num método iterativo para se determinar os autovalores de uma matriz simétrica, assim como uma matriz de covariância. Seja  $A$  a matriz de covariância,  $\lambda$  seus respectivos autovalores e  $x$  seus respectivos autovetores. Como apresentado na Equação 4.6 [D. V. Grif, 2006].

$$A.x = \lambda.x \quad (4.6)$$

Onde:

$A$  : Matriz de covariância.

$\lambda$  : Autovalores da matriz  $A$ .

$x$  : Autovetores da matriz  $A$ .

A Equação 4.6 pode ser transformada numa Equação com os mesmos autovalores, de acordo com a Equação 4.7.

$$A^*.x = \lambda.x \quad (4.7)$$

Onde:

$A^*$  : Matriz auxiliar.

$\lambda$  : Autovalores da matriz  $A$ .

$x$  : Autovetores da matriz  $A$ .

Se a Equação 4.6 for pós-multiplicada por uma matriz  $P$  e pré-multiplicada pela inversa da matriz  $P$ , conforme a Equação 4.7, será possível fazer  $A^*$  tomar a forma da Equação 4.8.

$$\begin{aligned} P^{-1}APx &= \lambda P^{-1}Px \\ A^* &= P^{-1}AP \\ A^* &= P^T APx = \lambda P^T Px \end{aligned} \tag{4.8}$$

Onde:

$A$ : Matriz de covariância.

$A^*$ : Matriz auxiliar.

$\lambda$ : Autovalores da matriz  $A$ .

$x$ : Autovetores da matriz  $A$ .

$P$ : Matriz ortogonal de transformação.

O conceito por trás dessa técnica de transformação é empregá-la de modo a tornar os autovalores de  $A^*$  mais fáceis de serem calculados do que os autovalores da matriz  $A$ . Para isso a matriz  $A$  deve ser simétrica, assim o cálculo dos autovalores será resolvido pela Equação 4.8. Para que os autovalores de  $A^*$  sejam os mesmos de  $A$  é necessário que  $P$  seja ortogonal. Matrizes com essa propriedade são denominadas matrizes de rotação, como pode ser visto na Equação 4.9.

$$\begin{aligned} P^T P &= I \\ P &= \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{bmatrix} \end{aligned} \tag{4.9}$$

Para matrizes com ordem superior a 2, a matriz de transformação é preenchida com 1 na diagonal principal e com zero nas demais posições, exceto nas posições nas quais será realizada a rotação. Um exemplo de matriz de rotação de ordem 4 é apresentado na Equação 4.10.

$$P = \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) & 0 & 0 \\ \sin(\alpha) & \cos(\alpha) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.10)$$

A matriz da Equação 4.10 elimina os termos (1,2) e (2,1) da matriz  $A$  de ordem 4 por meio da transformação por  $P^T A P$ . O incremento com 0s e 1s deixa os demais elementos de  $A$  sem alteração. No caso desse trabalho a matriz  $P$  utilizada para eliminar a matriz de covariância é dada na Equação 4.11.

$$P = \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \sin(\alpha) & \cos(\alpha) & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.11)$$

A diagonalização Jacobiana vai realizar em cada iteração a eliminação do maior termo da matriz  $A$  fora da diagonal principal por meio de uma matriz de rotação. Para que a transformação seja possível é necessário a cada iteração calcular o valor de  $\alpha$  por meio da Equação 4.12 [D. V. Grif, 2006].

$$\tan(2\alpha) = \frac{2a_{ij}}{a_{ii} - a_{jj}}, \text{ para } i \neq j \quad (4.12)$$

Onde:

$\alpha$  : ângulo de rotação.

$a_{ij}$ : Elementos da matriz  $A$ .

Ao término do processo a matriz  $A$  terá na sua diagonal principal os autovalores de  $A$ , e zero nas demais posições, como apresentado na Equação 4.13.

$$A = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} \quad (4.13)$$

A análise desses autovalores vai determinar quais serão as variáveis que deverão estar presentes no processamento da RNA. Após o cálculo da diagonalização Jacobiana o resultado é apresentado na matriz da Equação 4.14, onde a diagonal principal contém os autovalores da matriz de covariância  $A$ , apresentados na Tabela 4.3.

A observação desses valores permite ao projetista avaliar quais serão as variáveis que mais apresentam informação sem redundância para a execução da RNA e sem perda de características importantes do problema. Quanto maior o valor para uma determinada característica, maior sua importância para o projeto da RNA. Nesse caso, optou-se por considerar as variáveis que apresentassem um valor superior a 1. Assim, o grupo final de variáveis que será utilizado no projeto da RNA é apresentado na Tabela 4.4 [Lud, 2007].

$$\begin{aligned}
 & \text{(4.14)} \\
 P = & \begin{bmatrix}
 1,14 \times 10^{-4} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 2,35 \times 10^{-2} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 5,00 \times 10^{-1} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 2,00 \times 10^0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 1,14 \times 10^{-4} & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 5,06 \times 10^{-1} & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 2,00 \times 10^0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 7,20 \times 10^{-3} & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 3,03 \times 10^5 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 8,00 \times 10^2 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1,84 \times 10^4
 \end{bmatrix}
 \end{aligned}$$

Tabela 4.4: variáveis da célula solar baseadas no modelo determinístico – Variáveis selecionadas

Variável Aleatória $x_i$	Característica	Correlação Voc	Correlação Vpmp	Correlação Isc	Correlação Ipmp	Entropia $H(x)$	Autovalor
20	Concentração do elemento dopante tipo N: Determina a quantidade de dopante utilizado no semicondutor tipo N	0,102	0,174	0,168	0,108	1,602	2
23	Concentração do elemento dopante tipo P: Determina a quantidade de dopante utilizado no semicondutor tipo P	0,101	0,061	0,063	0,101	1,602	2
25	Intensidade Luminosa: Indica a quantidade de luz que a célula solar está submetida	1,000	0,706	0,721	0,999	4,135	$3,03 \times 10^5$
26	Temperatura: Indica a temperatura de funcionamento da célula solar	-0,052	-0,318	-0,280	-0,075	3,041	$8,00 \times 10^2$
29	Área: Determina o valor da célula solar	0,053	0,122	0,741	1,000	3,477	$1,84 \times 10^4$

### 4.3 Preparação dos dados do modelo PC-1D

Para a validação da técnica de modelagem por ferramentas de IC foi utilizado o programa PC-1D. Isso se deve ao fato de que o PC-1D é um dos principais softwares de modelagem de células solares da atualidade. Com esse software é possível determinar as propriedades elétricas da célula solar a partir das suas propriedades físicas [Sint, 2004]. Como o PC-1D utiliza a análise de elementos finitos para a resolução das equações de transporte de portadores no semicondutor em uma dimensão, a análise estatística da influência das variáveis na solução final do problema, como foi utilizado no software PMCCF e apresentada na seção 4.2, se tornou uma tarefa com grande complexidade.

Uma estratégia diferente foi utilizada para a validação dos dados a partir do modelo implementado pelo software PC-1D. A técnica de IC será responsável por estimar as propriedades físicas da célula solar a partir do seu comportamento operacional. Para esse cenário, os dados necessários para a modelagem através das ferramentas de IC são provenientes da leitura da curva I-V da célula solar, da corrente de curto-circuito, da tensão em circuito aberto, da potência máxima, da radiação solar, da temperatura ambiente e da área da célula solar. Todos esses dados podem ser mensurados diretamente do dispositivo fotovoltaico.

O objetivo da simulação é poder realizar diversas análises no dispositivo, como estimar o comportamento da célula no que se refere à densidade de corrente. Para a realização dessa análise proposta, é necessário inicialmente a definição dos parâmetros físicos da célula solar.

#### 4.3.1 Estimação dos parâmetros físicos do modelo PC-1D

Para a estimação dos principais parâmetros físicos presentes no modelo empregado pelo software PC-1D, a ferramenta a ser utilizada será uma RNA. Esta será constituída com uma arquitetura *feedforward*, *fully connected*, com algoritmo de treinamento *backpropagation* com uma função de ativação sigmoideal da forma da tangente hiperbólica.



O conjunto de dados de entrada será formado pelos dados provenientes da leitura da curva de caracterização elétrica da célula solar e das condições de operação. A resposta a ser obtida pela RNA é um conjunto de dados que representa as características físicas da célula solar, conforme apresentado na Tabela 4.5. Esses dados são utilizados nas equações de transporte dos portadores apresentados no Anexo I.

**Tabela 4.5: Parâmetros físicos utilizados pelo software PC-1D.**

<b>Característica</b>	<b>Unidade</b>
Profundidade da textura na superfície frontal	$\mu m$
Refletância frontal exterior	%
Contato de base	$\Omega$
Condutância interna	S
Espessura	$\mu m$
Concentração intrínseca a 300K	átomos.cm <sup>-3</sup>
Dopagem do semicondutor tipo P	átomos.cm <sup>-3</sup>
Dopagem do semicondutor tipo N	átomos.cm <sup>-3</sup>
Tempo de vida dos portadores minoritários elétrons	s
Tempo de vida dos portadores minoritários lacunas	s
Velocidade de recombinação superficial frontal tipo N	cm.s <sup>-1</sup>
Velocidade de recombinação superficial frontal tipo P	cm.s <sup>-1</sup>
Velocidade de recombinação superficial posterior tipo N	cm.s <sup>-1</sup>
Velocidade de recombinação superficial posterior tipo P	cm.s <sup>-1</sup>

Os dados de entrada são compostos pelos pontos da curva característica I-V da célula solar. Cada ponto é formado por um par ordenado da forma tensão e corrente, e são necessários 18 pontos ao longo da curva para representar seu perfil completo. Além dos pontos da curva, são utilizados como dados de entrada a corrente de curto-circuito, a tensão em circuito aberto, a potência máxima, a radiação solar, a temperatura ambiente e a área da célula solar. Portanto são 24 parâmetros de entrada utilizados nesse modelo. O fato de serem utilizados 18 pontos da curva I-V refere-se ao fato de que essa é a quantidade de pontos gerados pelo software PC-1D.

Cada um desses parâmetros necessita ser normalizado para ser possível utilizar o modelo da RNA. Como todos eles apresentam a mesma ordem de grandeza, apenas a normalização para a utilização com a função de ativação da RNA é necessária. Essa normalização visa colocar os valores no domínio da função sigmoidal tangente hiperbólica, limitada ao intervalo [-1,1] do conjunto dos números reais.

Os dados de saída da RNA, que representam as características físicas do modelo, conforme apresentado na Tabela 4.5, também necessitam ser normalizados, pois o

contradomínio da função sigmoideal tangente hiperbólica está contida no intervalo  $[-1,1]$  do conjunto de números reais.

Porém, algumas das propriedades do modelo apresentam valores com ordem de grandeza muito díspares. Isso faz com que a normalização dos mesmos crie uma representação ineficiente para o processamento da RNA, para o intervalo do domínio da função sigmoideal. Essa situação faz com que o modelo tenha grande dificuldade em convergir para os resultados esperados. As propriedades que apresentam valores com uma ordem de grandeza incompatível com o processamento a ser realizado, estão presentes na Tabela 4.6 e serão tratados de maneira diferenciada.

**Tabela 4.6: Propriedades com ordem de grandeza elevada**

<b>Característica</b>	<b>Unidade</b>	<b>Ordem de Grandeza</b>
Concentração intrínseca a 300K	átomos.cm <sup>-3</sup>	10 <sup>10</sup>
Dopagem do semicondutor tipo P	átomos.cm <sup>-3</sup>	10 <sup>16</sup>
Dopagem do semicondutor tipo N	átomos.cm <sup>-3</sup>	10 <sup>20</sup>
Velocidade de recombinação superficial frontal tipo N	cm.s <sup>-1</sup>	10 <sup>6</sup>
Velocidade de recombinação superficial frontal tipo P	cm.s <sup>-1</sup>	10 <sup>6</sup>
Velocidade de recombinação superficial posterior tipo N	cm.s <sup>-1</sup>	10 <sup>5</sup>
Velocidade de recombinação superficial posterior tipo P	cm.s <sup>-1</sup>	10 <sup>5</sup>

Assim a normalização desses valores segue um esquema diferente, onde o número referente ao valor típico é quebrado em duas entidades distintas. A primeira refere-se ao algarismo significativo e compreende o intervalo  $[1,9]$  no conjunto dos números reais. O segundo refere-se ao expoente do número e compreende os valores entre o menor e o maior expoente para cada número. Portanto são 21 as variáveis a serem calculadas pela RNA para a caracterização das propriedades físicas da célula solar, conforme a Tabela 4.7.

#### **4.3.2 Densidade de corrente**

Assim como é possível o modelo por IC estimar as propriedades físicas utilizadas pelo software PC-1D, é também possível o mesmo diretamente realizar algumas análises do comportamento da célula solar a partir dos dados de leitura. Uma das análises que é possível ser realizada é a verificação da densidade de corrente para cada um dos portadores.

Tabela 4.7: Propriedades a serem calculadas pela RNA

Item	Característica
1	Profundidade da textura na superfície frontal
2	Refletância frontal exterior
3	Contato de base
4	Condutância interna
5	Espessura
6	Concentração intrínseca a 300K – Algarismo principal
7	Concentração intrínseca a 300K – Expoente
8	Dopagem do semicondutor tipo P – Algarismo principal
9	Dopagem do semicondutor tipo P – Expoente
10	Dopagem do semicondutor tipo N – Algarismo principal
11	Dopagem do semicondutor tipo N – Expoente
12	Tempo de vida dos portadores minoritários elétrons
13	Tempo de vida dos portadores minoritários lacunas
14	Velocidade de recombinação superficial frontal tipo N – Algarismo principal
15	Velocidade de recombinação superficial frontal tipo N – Expoente
16	Velocidade de recombinação superficial frontal tipo P – Algarismo principal
17	Velocidade de recombinação superficial frontal tipo P – Expoente
18	Velocidade de recombinação superficial posterior tipo N – Algarismo principal
19	Velocidade de recombinação superficial posterior tipo N – Expoente
20	Velocidade de recombinação superficial posterior tipo P – Algarismo principal
21	Velocidade de recombinação superficial posterior tipo P – Expoente

Para a realização dessa análise serão utilizadas três RNAs. Uma terá como foco o cálculo da densidade de corrente de acordo com a distância da superfície da célula para os elétrons. Outra RNA terá como foco o cálculo da densidade de corrente de acordo com a distância da superfície da célula para as lacunas e uma terceira RNA irá calcular a densidade de corrente total. Para essa análise, todas as RNAs serão constituídas com uma arquitetura *feedforward*, *fully conectad*, com algoritmo de treinamento *backpropagation* com uma função de ativação sigmoideal da forma da tangente hiperbólica.

Assim como a primeira RNA, para determinação das propriedades físicas, estas também farão uso dos dados da curva I-V, da corrente de curto-circuito, da tensão em circuito aberto, da potência máxima, da intensidade luminosa, da temperatura ambiente e da área da célula solar, perfazendo um total de 24 parâmetros de entrada para o modelo.

Cada saída da RNA irá expressar sua resposta de acordo com o foco da mesma, ou seja, densidade de corrente dos elétrons, densidade de corrente das lacunas e densidade de corrente total. Para esse cálculo cada RNA irá expressar sua resposta em 160 pontos formados pelo par ordenado distância da superfície e densidade de corrente. Isso se deve ao fato do software PC-1D utilizar essa estrutura para realizar essa análise.

Tanto os parâmetros de entrada quanto os de saída necessitam ser normalizados para ser possível utilizar o modelo da RNA. Como todos eles apresentam a mesma ordem de grandeza, apenas a normalização para a utilização com a função de ativação da RNA é necessária. Essa normalização visa colocar os valores no domínio e no contradomínio da função sigmoideal tangente hiperbólica.

Com o emprego das metodologias de preparação dos dados, conforme apresentado no capítulo 4, será possível a utilização da técnica proposta neste projeto. Os resultados dos processamentos para ambos os modelos utilizados para análise serão apresentados no próximo capítulo. A discussão sobre os resultados encontrados e sobre a utilização da técnica será abordada no capítulo 6.

# Capítulo 5

## **Análise da Aplicação das Ferramentas de IC aos modelos de Teste**

### **5.1 Introdução**

A partir da metodologia elaborada, um conjunto de testes para validar a técnica de IC foram produzidos. Foram realizados um conjunto de testes nos dois softwares que utilizam modelos para representar o comportamento elétrico de células fotovoltaicas a partir das suas propriedades físicas, o PMCCF e o PC-1D. Para ambos os modelos foram gerados gráficos e tabelas para expressar os resultados obtidos.


Os resultados encontrados mostram a validade da técnica e a possibilidade de expandir sua utilização para a realização de diversas análises sobre o comportamento elétrico e físico de células fotovoltaicas.

### **5.2 Resultados da modelagem do software PMCCF com o Sistema Híbrido Genético (SHG)**

Como descrito no capítulo 4, o SHG irá utilizar uma RNA como função de avaliação do AG. Isso faz com que a estrutura da RNA tenha grande impacto no resultado final do processamento. A determinação dessa estrutura leva em consideração as características próprias do problema, assim como a própria observação do processamento

da RNA, sendo este, portanto, uma determinação empírica de acordo com as condições de processamento num determinado instante. No Apêndice - E é apresentada uma tabela dos processamentos realizados de acordo com diversas configurações para a RNA para o modelo PMCCF, a tabela de configuração para a estrutura da RNA utilizada e a representação dos dados utilizados na RNA.

As respostas encontradas pela RNA para o modelo implementado pelo PMCCF expressam bastante significância se comparadas com o modelo determinístico que foi utilizado, e cujas equações estão presentes no Apêndice F. Isso pode ser determinado de diversas maneiras, como por exemplo, ao se observar o erro médio quadrático encontrado de  $1,05 \times 10^{-5}$  ao final de 41404 iterações, conforme apresentado na Figura 5.1. Esse valor implica que é esperado um erro máximo na resposta da RNA em relação ao modelo determinístico na faixa de  $3,0 \times 10^{-3}$ ; ou seja, é esperado um erro cumulativo máximo de 1,52% para cada resposta encontrada, considerando o padrão de saída de dados formado pela corrente de curto-circuito, corrente no ponto de máxima potência, tensão em circuito aberto e tensão no ponto de máxima potência.



**Fig. 5.1: Gráfico do processamento do erro médio quadrático para a RNA.**

O sistema híbrido genético é a ferramenta necessária para estimar a composição dos dopantes utilizados no processo de fabricação da célula solar. O conhecimento preciso dos tipos de dopantes utilizados e suas respectivas concentrações é uma informação de suma importância devido ao fato de que os mesmos possuem influência direta no comportamento funcional da célula fotovoltaica e são características intrínsecas do processo de fabricação. Essas características causam modificações em fatores importantes do comportamento da célula, como a corrente de curto-circuito, a tensão em circuito aberto, os pontos de tensão e corrente para a potência máxima e a corrente reversa de saturação. Outros fatores, como o comprimento da camada de depleção e o tempo de vida dos portadores minoritários também são afetados pela mudança do tipo e concentração dos dopantes [Mat, 2006].

A construção de um sistema híbrido genético vai proporcionar a resolução do problema de estimar os tipos e concentrações dos dopantes através de um processo estocástico probabilístico [Hag, 2003]. Para isso, será utilizada a RNA treinada com o modelo determinístico para atuar como a função de avaliação (*fitness*) do Algoritmo Genético, cujo erro médio quadrático é apresentado na Figura 5.1. O espaço de busca do AG será, então, responsável por gerar as condições de entrada para a RNA, compará-las com as saídas apresentadas e confrontá-las com as medidas esperadas.

Cada tipo de dopante, assim como a sua respectiva concentração, modifica de uma maneira singular a curva de resposta da célula solar. Essa modificação pode, em alguns casos, ser ínfima, estando presente dentro da faixa de erro da RNA. O que leva a possíveis falhas de determinação para uma única curva de avaliação, devido principalmente à sobreposição de alguns pontos da curva para uma condição de operação [Kin, 1997]. Assim, o modelo necessita de um conjunto de curvas, medidas de uma célula solar para diferentes condições de irradiação solar e temperatura, para determinar a probabilidade de ocorrência de um determinado tipo de dopante e sua respectiva concentração. A descrição do SHG está presente no apêndice D.

### 5.2.1 Execução e análise dos resultados SHG

O sistema híbrido genético utiliza a RNA para avaliar a qualidade da resposta no processo de estimação dos portadores. Cada indivíduo, é então, analisado pela função *fitness* e o valor do erro encontrado entre as saídas presentes no cromossomo e as encontradas pela RNA são medidas em módulo, conforme apresentado na Equação 5.1. A representação do cromossomo pode ser observada na Figura 5.2.

0,732	0,550	0,200	0,500	0,800	0,666	0,000	0,300	1,000	0,250	0,550	0,600	0,270
(a)	(b)	(c)	(d)	(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)	(m)

**Fig. 5.2: Representação do cromossomo manipulado pelo AG, de acordo com o posicionamento do seu campo de referência: (a) irradiação solar, (b) temperatura, (c) área, (d) tipo de dopante N, Concentrações: [(e) dopante N, (f) grandeza], (g) tipo de dopante P, Concentrações: [(h) dopante P, (i) grandeza], (j)  $I_{pmp}$ , (k)  $V_{pmp}$ , (l)  $V_{oc}$ , (m)  $I_{sc}$ .**

Quanto menor a diferença entre o resultado do cromossomo e o resultado calculado pela RNA, melhor será a resposta e mais apto será o indivíduo gerado. O total de indivíduos escolhidos para participar do novo processo de seleção, cruzamento e mutação é igual ao total de indivíduos da população inicial estabelecidos como parâmetro de utilização do SHG. O processo se repete enquanto um determinado número de ciclos, estabelecidos como parâmetro de execução não seja alcançado, ou um valor mínimo para o erro não seja obtido.

$$E = |(j) - s_1| + |(k) - s_2| + |(l) - s_3| + |(m) - s_4| \quad (5.1)$$

Onde:

$E$ : Erro total encontrado.

$(j), (k), (l), (m)$ : Campos do Cromossomo.

$s_1, s_2, s_3, s_4$ : Saídas da RNA relacionadas com os campos do cromossomo.

Desta forma, a função do SHG é minimizar o erro apresentado pela Equação 5.1. Após o término do número de ciclos, o indivíduo com menor erro apresentará os tipos de dopantes e concentrações esperados para os dados de operação e leitura da célula solar.

Como a RNA utilizada apresenta um erro médio global de  $1,05 \times 10^{-5}$ , isso acarreta num erro de aproximadamente  $3,0 \times 10^{-3}$  calculado nos neurônios de saída. Essa diferença é



suficientemente grande para criar uma indeterminação no tipo de curva gerada no processamento do SHG. Isso porque tanto a troca por determinados tipos de dopantes e /ou modificação das suas concentrações, é possível aproximar a curva comportamental de uma célula fotovoltaica dopada com uma determinada configuração de dopantes (tipo de dopantes N e P e suas respectivas concentrações) de outra com outro tipo de configuração. Porém, quando é analisado um pacote de curvas de uma célula solar para diferentes condições de irradiação solar e temperatura, sobressalta os resultados referentes à configuração de fabricação correta. Assim, os resultados encontrados pelo SHG não podem ser vistos isoladamente, mas sim num contexto onde um certo número de curvas é analisado, sendo que de acordo com a frequência relativa apresentada pela teoria estatística, com o maior número de casos de curvas analisados, mais confiante será o resultado obtido.

Para demonstrar essa situação foi realizado um conjunto de leituras para diferentes condições de irradiação solar e temperatura para uma célula solar dopada com fósforo (P) e boro (B) com a concentração de  $5 \times 10^{15}$  átomos.cm<sup>-3</sup> e  $1 \times 10^{13}$  átomos.cm<sup>-3</sup> respectivamente. A Tabela 5.1 apresenta os resultados encontrados pelo SHG para as condições de operação da célula solar.

O processamento estatístico para os resultados encontrados pelo SHG é apresentado na Tabela 5.2. É a partir desses resultados que é determinado o dopante tipo N. Na Tabela 5.3 é apresentado o processamento da média para os resultados encontrados para a concentração do dopante tipo N pelo SHG. Como esse campo o próprio valor é encontrado, este é utilizado para estimar a média. Na Tabela 5.4 é apresentado o processamento estatístico para os resultados encontrados para a grandeza da concentração do dopante tipo N pelo SHG. O processamento estatístico para os resultados encontrados pelo SHG é apresentado na Tabela 5.5. É a partir desses resultados que é determinado o dopante tipo P.

**Tabela 5.1: Resultados encontrados pelo SHG**

Exemplo	Elemento N	Concentração	Grandeza	Elemento P	Concentração	Grandeza	Irradiação W.m <sup>-2</sup>	Temperatura °C
1	0,500 (Sb)	0,100	0,000	0,300 (Al)	0,400	0,333	1000	25
2	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	800	25
3	1,000 (P)	0,200	0,333	0,000 (B)	0,100	0,000	600	25
4	1,000 (P)	0,500	1,000	0,000 (B)	0,100	0,000	400	25
5	1,000 (P)	0,200	0,000	0,000 (B)	0,700	0,666	200	25
6	0,000 (As)	0,400	0,666	0,000 (B)	0,200	0,000	1000	-10
7	0,000 (As)	0,400	0,666	0,000 (B)	0,200	0,000	1000	0
8	0,000 (As)	0,700	1,000	0,600 (Ga)	0,200	0,666	1000	15
9	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	1000	45
10	0,500 (Sb)	0,700	0,666	0,300 (Al)	0,200	0,000	1000	60
11	1,000 (P)	0,300	0,666	1,000 (In)	0,600	0,666	800	-10
12	1,000 (P)	0,600	1,000	0,000 (B)	0,100	0,000	800	0
13	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	800	15
14	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	800	45
15	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	800	60
16	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	600	-10
17	1,000 (P)	0,300	0,666	0,000 (B)	0,100	0,000	600	0
18	0,000 (As)	0,300	0,333	0,600 (Ga)	0,200	0,333	600	15
19	0,000 (As)	0,400	0,333	0,300 (Al)	0,800	1,000	600	45
20	1,000 (P)	0,200	0,333	0,000 (B)	0,100	0,000	600	60
21	1,000 (P)	0,500	0,666	0,000 (B)	0,100	0,000	400	-10
22	1,000 (P)	0,500	0,666	0,000 (B)	0,100	0,000	400	0
23	0,000 (As)	0,400	0,333	0,300 (Ga)	0,900	1,000	400	15
24	1,000 (P)	0,400	1,000	0,000 (B)	0,100	0,000	400	45
25	1,000 (P)	0,100	0,000	0,300 (Al)	0,900	0,666	400	60
26	1,000 (P)	0,700	0,666	0,300 (Al)	0,100	0,333	200	-10
27	1,000 (P)	0,200	0,000	0,000 (B)	0,700	0,666	200	0
28	1,000 (P)	0,200	0,000	0,000 (B)	0,700	0,666	200	15
29	0,500 (Sb)	0,200	0,000	0,600 (Ga)	0,600	0,333	200	45
30	0,500 (Sb)	0,200	0,000	0,600 (Ga)	0,800	0,666	200	60

**Tabela 5.2: Tipo de dopante para o semicondutor tipo N.**

Valor Simbólico	Valor Representado	Percentual Estatístico
0,000	(As)	20,00%
0,500	(Sb)	13,34%
1,000	(P)	66,67%

**Tabela 5.3: Média da concentração do dopante tipo N**

Média Encontrada	Valor sem normalização
0,35	3,5

**Tabela 5.4: Média para a grandeza do dopante N**

Valor Simbólico	Valor Representado	Percentual Estatístico
0,000	$10^{13}$	23,34%
0,333	$10^{14}$	16,67%
0,666	$10^{15}$	46,67%
1,000	$10^{16}$	13,37%

**Tabela 5.5: Elementos dopante para o semicondutor tipo P**

Valor Simbólico	Valor Representado	Percentual Estatístico
0,000	(B)	63,37%
0,300	(Al)	20,00%
0,600	(Ga)	13,37%
1,000	(In)	03,34%

Na Tabela 5.6 é apresentado o processamento da média para os resultados encontrados para a concentração do dopante tipo P pelo SHG. Da mesma forma da concentração tipo N, como esse campo o próprio valor é encontrado, este é utilizado para estimar a média.

**Tabela 5.6: Média da concentração do dopante tipo P**

Média Encontrada	Valor sem normalização
0,17	1,7

Na Tabela 5.7 é apresentado o processamento médio para os resultados encontrados para a grandeza da concentração do dopante tipo P pelo SHG.

**Tabela 5.7: Média para a grandeza do dopante tipo P**

Valor Simbólico	Valor Representado	Percentual Estatístico
0,000	$10^{13}$	56,67%
0,333	$10^{14}$	13,37%
0,666	$10^{15}$	23,34%
1,000	$10^{16}$	06,67%

Desta forma, os resultados possíveis que melhor representam a configuração da célula solar segundo o SHG são apresentados na Tabela 5.8.


**Tabela 5.8: Configuração apresentada como resultado do sistema híbrido**

Elemento N	Concentração (átomos.cm <sup>-3</sup> )	Grandeza	Elemento P	Concentração (átomos.cm <sup>-3</sup> )	Grandeza
(P)	3,5	10 <sup>15</sup>	(B)	1,7	10 <sup>13</sup>


Os resultados encontrados pelo SHG são idênticos quando são comparados os campos referentes aos elementos do tipo N e P, assim como os dados referentes à grandeza de concentração. Já os campos referentes ao algarismo significativo da concentração propriamente dita apresentam uma diferença de cerca de 15% em relação à concentração do elemento tipo N e de 7% com relação à concentração do elemento tipo P. Como ambos se encontram na mesma grandeza de concentração esperada para os resultados, essa diferença apresenta pouca variância dos resultados da curva determinada por esse tipo de configuração, permitindo assim, uma visão bem fidedigna da configuração de fabricação da célula solar, conforme apresentado nas figuras a seguir.

A Figura 5.3 apresenta a resolução encontrada pelo SHG presente no exemplo 1 da Tabela 5.1, para a curva I-V. Na Figura 5.4 é apresentada a curva P-V. É feito um comparativo entre as curvas encontradas pelo SHG, da configuração da célula utilizada como controle de teste e da média dos resultados encontrados e apresentados na Tabela 5.8 para uma configuração de iluminação de 1000 W/m<sup>2</sup> e uma temperatura de 25 °C.

Como apresentado no exemplo 1 da Tabela 5.1, embora o SHG não tenha encontrado corretamente os elementos constituintes da célula solar com suas respectivas concentrações, a configuração determinada pelo simulador SHG consegue aproximar as curvas de resultados da célula solar.




**Fig. 5.3:** Leitura para uma irradiação solar de  $1000 \text{ W/m}^2$  e  $25^\circ\text{C}$  para a curva I-V. Média encontrada pelo SHG, Curva de controle do modelo PMCCF e a curva encontrada pelo SHG do exemplo 1 da Tabela 5.1.




**Fig. 5.4:** Leitura para uma irradiação solar de  $1000 \text{ W/m}^2$  e  $25^\circ\text{C}$  para a curva P-V. Média encontrada pelo SHG, Curva de controle do modelo PMCCF e a curva encontrada pelo SHG do exemplo 1 da Tabela 5.1.

A Figura 5.5 apresenta a resolução encontrada pelo SHG presente no exemplo 6 da Tabela 5.1, para a curva I-V. Na Figura 5.6 é apresentada a curva P-V. É feito um comparativo entre as curvas encontradas pelo SHG, da configuração padrão da célula utilizada como controle e da média dos resultados encontrados e apresentados na Tabela 5.8 para uma configuração de irradiação solar de  $1000 \text{ W/m}^2$  e uma temperatura de  $-10^\circ\text{C}$ .



**Fig. 5.5:** Leitura para uma irradiação de  $1000 \text{ W/m}^2$  e  $-10^\circ \text{C}$  para a curva I-V, Média encontrada pelo SHG, Curva de controle do modelo PMCCF e a curva encontrada pelo SHG do exemplo 6 da Tabela 5.1.




**Fig. 5.6:** Leitura para uma irradiação solar de  $1000 \text{ W/m}^2$  e  $-10^\circ \text{C}$  para a curva de potência, Média encontrada pelo SHG, Curva de controle do modelo PMCCF e a curva encontrada pelo SHG do exemplo 6 da Tabela 5.1.


Já no caso apresentado no exemplo 6 da Tabela 5.1, o SHG encontrou corretamente os elementos constituintes da célula solar, e suas concentrações se aproximam da concentração da célula solar utilizada para controle e teste. É possível observar que a configuração determinada pelo simulador SHG consegue aproximar tanto a curva referente à configuração de controle da célula, quanto a curva representante da média encontrada. Em ambos os casos pode-se perceber que as curvas com os valores da média calculada e presente na Tabela 5.8 estão bem próximo da curva característica da célula solar utilizada como controle e teste, mostrando que a técnica apresentou bons resultados referente à determinação da curva característica.

A Figura 5.7 apresenta um comparativo entre o resultado das curvas características I-V para a média na Tabela 5.8 e para o valor de controle da célula solar utilizado como comparação às temperaturas de  $25^{\circ}\text{C}$  e  $60^{\circ}\text{C}$  sob uma irradiação solar de  $1000\text{ W/m}^2$ . Pode se observar que a diferença na tensão entre do resultado da média para o controle é de 18 mV. Na Figura 5.8 a comparação é realizada em termos da curva de potência, onde a diferença no ponto de máxima potência é de 300 mW. Na Figura 5.9, o comparativo das curvas I-V é realizada para as condições de irradiação solar de  $1000\text{ W/m}^2$  e  $300\text{ W/m}^2$ , porém a uma temperatura fixa de  $25^{\circ}\text{C}$ . Nessa condição de operação a diferença foi de 11 mV. A Figura 5.10 apresenta o comparativo em relação às curvas de potências para as condições de irradiação solar de  $1000\text{ W/m}^2$  e  $300\text{ W/m}^2$ , também a  $25^{\circ}\text{C}$  e a diferença de potência no ponto de máximo foi de 220 mW.





**Fig. 5.7:** Leitura para uma irradiação solar de  $1000 \text{ W/m}^2$  da curva I-V. Comparativo das curvas de controle do modelo PMCCF e média encontrada pelo SHG para as temperaturas de 25 e  $60^\circ \text{C}$ .



**Fig. 5.8:** Leitura para uma irradiação solar de  $1000 \text{ W/m}^2$  da curva de potência. Comparativo das curvas de controle do modelo PMCCF e média encontrada pelo SHG para as temperaturas de 25 e  $60^\circ \text{C}$ .




Fig. 5.9: Leitura para a temperatura de  $25^{\circ}\text{C}$  da curva I-V. Comparativo das curvas de controle do modelo PMCCF e média encontrada pelo SHG para irradiância de  $300\text{ W.m}^{-2}$  e  $1000\text{ W.m}^{-2}$




Fig. 5.10: Leitura para a temperatura de  $25^{\circ}\text{C}$  da curva Potência. Comparativo das curvas de controle do modelo PMCCF e média encontrada pelo SHG para irradiância de  $300\text{ W.m}^{-2}$  e  $1000\text{ W.m}^{-2}$


### 5.3 O modelo PC-1D

O modelo implementado pelo software PC-1D utiliza um conjunto de dados para realizar a modelagem das propriedades físicas da célula solar. Para solucionar as equações de transporte dos portadores em uma dimensão, utilizados nesse modelo, o PC-1D utiliza a técnica de resolução por elementos finitos, e o conjunto das principais equações está presente no Anexo 1.


A descoberta das características físicas a partir do comportamento da célula solar vai permitir a realização de um conjunto de análises que seriam inviáveis sem o conhecimento desses valores. Como exemplo de análise pode-se citar: densidade de dopantes, densidade de portadores, potencial eletrostático, campo elétrico, densidade de carga, densidade de corrente, geração e recombinação de portadores, mobilidade de portadores entre outros. No escopo desse trabalho será feita a análise referente à densidade de corrente focando separadamente a densidade gerada pelos elétrons, lacunas e a densidade de corrente total.

As principais propriedades utilizadas pelo software PC-1D podem ser deduzidas diretamente da leitura da curva I-V e das condições de operação da célula solar por meio do processamento de uma RNA. Nesse estudo foi realizada a estimação dos parâmetros presentes na Tabela 5.9. Conforme apresentado no capítulo 4, uma RNA será utilizada para estimar essas propriedades. Para isso um conjunto de dados foi utilizado como padrão de treinamento compostos pelos pontos da curva característica I-V da célula solar (18 pontos formados por um par ordenado da forma tensão e corrente ao longo da curva), da corrente de curto-circuito, da tensão em circuito aberto, da potência máxima, da irradiação solar, da temperatura ambiente e da área da célula solar. Como padrão de treinamento de saída, os dados da Tabela 5.9. A Figura 5.11 apresenta a forma da curva de entrada dos dados utilizados na RNA.

Durante o processamento da RNA foi observada a convergência dos resultados para os parâmetros esperados, possibilitando, assim, a estimação das propriedades físicas a partir da leitura do comportamento da célula solar. Na Figura 5.12 está presente a evolução do erro médio quadrático de acordo com as iterações realizadas pelo sistema.



**Fig. 5.11: Exemplo de uma curva I-V utilizada como entrada de dados para a RNA.**



**Fig. 5.12: Erro médio quadrático para as principais características do software PC-1D.**


O erro médio quadrático encontrado após 50.000 interações foi de  $2,85 \times 10^{-2}$ . Uma tabela com os processamentos utilizados está presente no apêndice E.

**Tabela 5.9: Características físicas da célula solar a serem estimadas pela RNA.**


<b>Característica</b>	<b>Unidade</b>
Profundidade da textura na superfície frontal	$\mu m$
Refletância frontal exterior	%
Contato de base	$\Omega$
Condutância interna	S
Espessura	$\mu m$
Concentração intrínseca a 300K	átomos.cm <sup>-3</sup>
Dopagem do semicondutor tipo P	átomos.cm <sup>-3</sup>
Dopagem do semicondutor tipo N	átomos.cm <sup>-3</sup>
	s
Tempo de vida dos portadores minoritários elétrons	s
Tempo de vida dos portadores minoritários lacunas	s
Velocidade de recombinação superficial frontal tipo N	cm.s <sup>-1</sup>
Velocidade de recombinação superficial frontal tipo P	cm.s <sup>-1</sup>
Velocidade de recombinação superficial posterior tipo N	cm.s <sup>-1</sup>
Velocidade de recombinação superficial posterior tipo P	cm.s <sup>-1</sup>

### 5.3.1 Análise da densidade de corrente

Para exemplificar a versatilidade da utilização da modelagem da célula solar por ferramentas de IC, foram realizadas as análises da densidade de corrente a partir da leitura do comportamento para determinadas condições de operação. A verificação da densidade de corrente será observada sob três prismas distintos. Inicialmente será observada a densidade de corrente gerada pelos elétrons de acordo com a sua posição dentro do material. Essa análise vai permitir verificar o comportamento da concentração da corrente devido à influência dos elétrons. A Figura 5.13 apresenta o gráfico do erro médio quadrático para o cálculo da densidade de corrente proveniente dos elétrons. As Figuras 5.14, 5.15 e 5.16 apresentam a comparação entre os parâmetros de teste e o calculado pela RNA para três curvas calculadas.



**Fig. 5.13:**Gráfico do erro médio quadrático para a análise da densidade de corrente a partir dos elétrons.



**Fig. 5.14:**Comparação da curva da densidade de corrente devido aos elétrons de acordo com a profundidade da célula solar. Exemplo - 1.




Fig. 5.15: Comparação da curva da densidade de corrente devido aos elétrons de acordo com a profundidade da célula solar. Exemplo – 2.





Fig. 5.16: Comparação da curva da densidade de corrente devido aos elétrons de acordo com a profundidade da célula solar. Exemplo – 3.

Pode-se observar que, para os exemplos apresentados, a medida da densidade de corrente proveniente dos elétrons, a RNA conseguiu praticamente sobrepor os resultados referentes aos valores encontrados pelo software PC-1D, com erro médio inferior a 1%. Para uma completa análise da densidade de corrente é necessário observar também a densidade de corrente devido à influência das lacunas de acordo com a profundidade da célula solar. Essa análise vai permitir verificar o comportamento da concentração da corrente devido à influência das lacunas no interior do semiconductor. A Figura 5.17 apresenta o gráfico do erro médio quadrático para a resolução da análise da densidade de corrente a partir das lacunas. As Figura 5.18, 5.19 e 5.20 apresentam a comparação entre os parâmetros do PC-1D e o calculado pela RNA para os exemplos utilizando a RNA.



**Fig. 5.17: Gráfico do Erro Médio Quadrático para a análise da densidade de corrente gerada pelas lacunas.**






Fig. 5.18: Comparação da curva da densidade de corrente devido a influência das lacunas de acordo com a profundidade da célula solar. Exemplo – 1.






Fig. 5.19: Comparação da curva da densidade de corrente devido a influência das lacunas de acordo com a profundidade da célula solar. Exemplo – 2.




**Fig. 5.20: Comparação da curva da densidade de corrente devido a influência das lacunas de acordo com a profundidade da célula solar. Exemplo – 3.**

A RNA conseguiu realizar a convergência dos resultados entre a simulação realizada e os resultados obtidos pelo software PC-1D. Isso pode ser observado para a medida da densidade de corrente proveniente das lacunas, a RNA conseguiu aproximar os resultados referentes aos valores encontrados pelo software PC-1D, com erro médio inferior a 2% a partir da leitura dos dados comportamentais da célula solar.

Para completar a análise referente à densidade de corrente é importante observar a densidade de corrente total do dispositivo (soma da densidade de corrente dos elétrons e lacunas) de acordo com a profundidade na célula solar. A Figura 5.21 apresenta o gráfico do Erro Médio Quadrático para a análise da corrente total. As Figuras 5.22, 5.23 e 5.24 apresentam a comparação entre os parâmetros de teste e os calculados pela RNA. A RNA conseguiu aproximar os resultados da simulação dos resultados obtidos pelo software PC-1D. Isso pode ser observado para a medida da densidade de corrente total, a aproximação realizada pela RNA reflete os erros para os resultados individuais da densidade de corrente encontrados a partir dos elétrons e lacunas. Mesmo assim o erro médio foi inferior a 3% a partir da leitura dos dados comportamentais da célula solar.



**Fig. 5.21:**Gráfico do Erro Médio Quadrático para a análise da densidade de corrente gerada pelas lacunas.



**Fig. 5.22:**Comparação da curva da densidade de corrente total de acordo com a profundidade da célula solar. Exemplo – 1.




Fig. 5.23: Comparação da curva da densidade de corrente total de acordo com a profundidade da célula solar. Exemplo – 2.




Fig. 5.24: Comparação da curva da densidade de corrente total de acordo com a profundidade da célula solar. Exemplo – 3.

## 5.4 Representação Gráfica dos modelos implementados

A representação gráfica dos modelos que foram utilizados para a obtenção dos resultados apresentados nas seções 5.2 e 5.3 estão presentes na Figura 5.25 que apresenta o esquema utilizado na modelagem do PMCCF, e na Figura 5.26 que representa o esquema utilizado para a obtenção da análise de densidade de corrente do modelo do PC-1D.

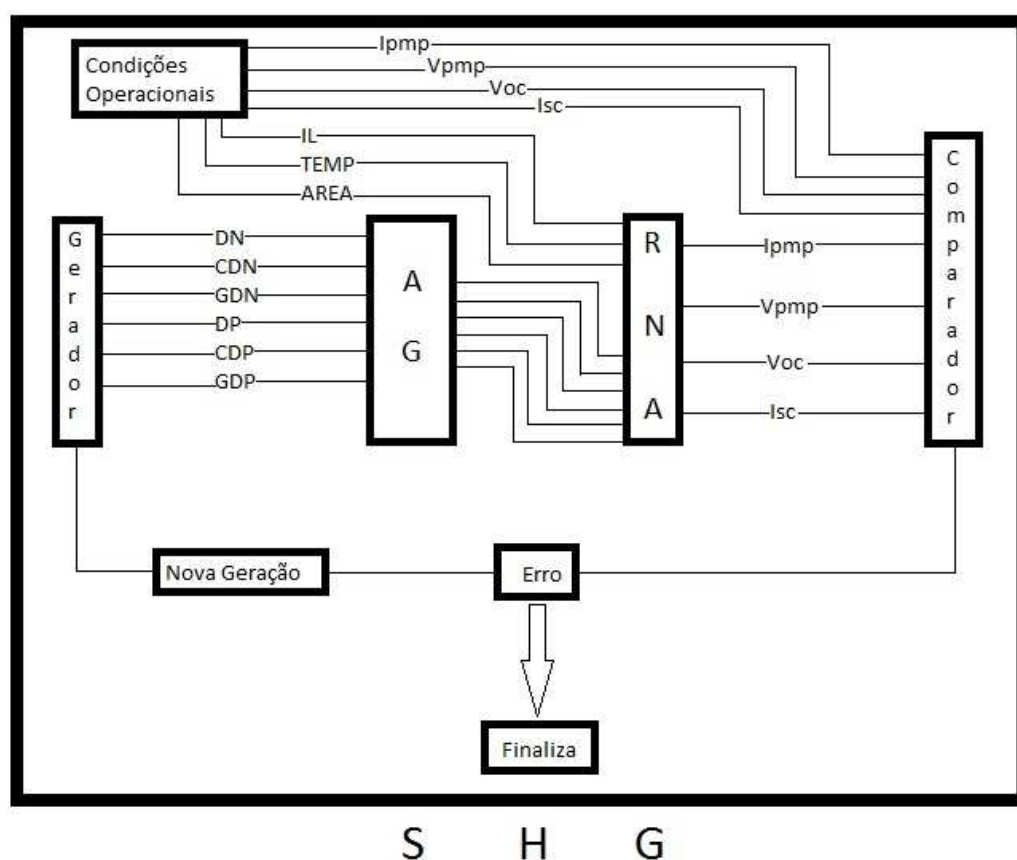
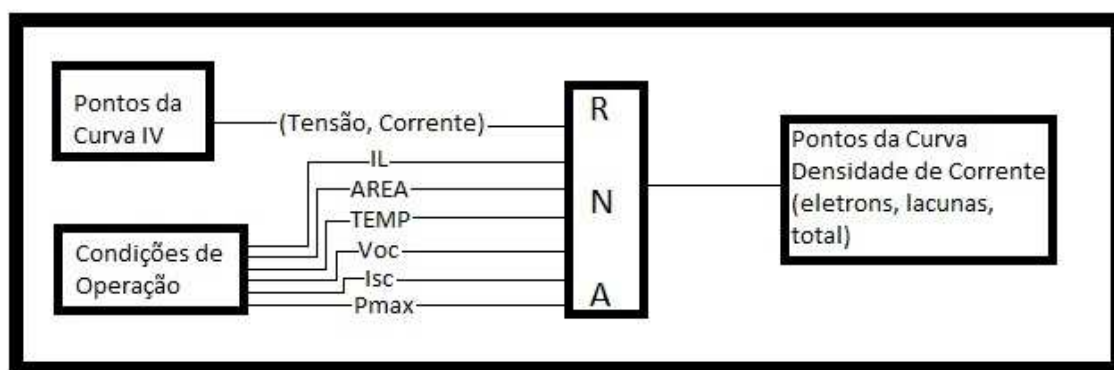


Fig. 5.25: Representação do esquema de funcionamento do SHG.

Na Figura 5.25 é feita a leitura das condições operacionais da célula fotovoltaica. Os itens observados são: irradiância ( $I_L$ ), temperatura ( $TEMP$ ), área ( $AREA$ ), corrente no ponto de máxima potência ( $I_{mp}$ ), tensão no ponto de máxima potência ( $V_{mp}$ ), tensão em circuito aberto ( $V_{oc}$ ) e corrente de curto-circuito ( $I_{sc}$ ). O Sistema Híbrido Genético (SHG) através do gerador de população gera os dopantes e suas respectivas concentrações: dopante

tipo N (DN), algarismo significativo da concentração do dopante tipo N (CDN), grandeza de concentração do dopante tipo N (GDN), dopante tipo P (DP), algarismo significativo da concentração do dopante tipo P (CDP), grandeza de concentração do dopante tipo P (GDP). No módulo AG são aplicados os operadores genéticos de seleção, cruzamento e mutação; e então é passado para a RNA fazer a avaliação, encontrando os resultados para os pontos da curva de dados representados por: corrente no ponto de máxima potência ( $I_{pmp}$ ), tensão no ponto de máxima potência ( $V_{pmp}$ ), tensão em circuito aberto ( $V_{oc}$ ), corrente de curto-circuito ( $I_{sc}$ ).

A resposta da RNA é comparada com os valores obtidos da leitura das condições operacionais pelo comparador onde é gerado um erro entre a leitura obtida e a resposta da RNA. Esse erro é, então, observado, caso esteja dentro de um limiar pré-determinado, o sistema se encerra e os valores para os tipos de dopantes e os picos de concentração são determinados. Caso contrário é solicitado à geração de uma nova população para o gerador que irá selecionar os indivíduos mais aptos para a realização de um novo processamento.



**Fig. 5.26: Análise da curva de densidade de corrente do modelo PC-1D.**

Na Figura 5.26 a leitura do modelo utilizado no software PC-1D é feita através da leitura dos pontos presentes na curva I-V formado pelo par ordenado (Tensão, Corrente). Além desses pontos (18 no total), a RNA recebe como parâmetros de entrada as condições de operação da célula solar, são eles: irradiância (IL), área (AREA), temperatura (TEMP), tensão em circuito aberto ( $V_{oc}$ ), corrente de curto-circuito ( $I_{sc}$ ) e a potência máxima ( $P_{max}$ ).

A resposta da RNA é um conjunto de pares ordenados da forma (densidade de corrente, profundidade) onde é possível observar o comportamento da densidade de corrente a partir das condições operacionais da célula solar.

Depois de realizados todos os testes sobre o modelo e verificados os resultados encontrados, faz-se necessário uma discussão dos resultados e uma análise da utilização da técnica. Essa discussão é apresentada no capítulo seguinte.

# Capítulo 6

## Conclusão e Discussão dos Resultados

### 6.1 Introdução

A pesquisa apresentou resultados significativos sobre a modelagem computacional de células fotovoltaicas a partir do uso de ferramentas de inteligência computacional para a estimação das propriedades físicas da mesma. Com o levantamento bibliográfico foi possível observar que a parte teórica se mostrou suficientemente embasada para comprovar a veracidade do método. Isso fica evidente quando observado os inúmeros exemplos de aplicação das ferramentas de IC aos mais diversos ramos, inclusive em fontes alternativas de energia. Da mesma forma, a fundamentação matemática se mostrou adequadamente poderosa para permitir obter as características físicas da célula solar a partir da sua condição de operação através das ferramentas de IC, e fornecer subsídios suficientes para a completa formulação e resolução do problema.

As ferramentas desenvolvidas com as bases teóricas apresentadas mostraram ser um caminho viável para a resolução do problema proposto. A configuração de cada uma delas pode ser variável para se adequar às diversas possibilidades de resolução e níveis de detalhamento de acordo com as possíveis formatações e disponibilidade dos dados. O estudo realizado sobre modelo PMCCF permitiu encontrar os resultados referentes às características elétricas da célula solar a partir de um conjunto mínimo de fatores que a princípio influenciam de forma mais incisiva o comportamento da curva I-V. Já o estudo do modelo utilizado pelo PC-1D permitiu não somente obter as configurações físicas e



construtivas básicas da célula solar, mas também abriu a possibilidade de realizar diversas análises diretamente da célula a partir das suas condições de operação.

Os resultados obtidos representam uma boa aproximação dos dados esperados presentes nos modelos estudados, dentro de uma margem de precisão considerada segura para a perfeita interpretação da resposta das ferramentas.

## 6.2 Discussão sobre a utilização das ferramentas

Foram utilizados dois tipos de ferramentas do campo da IC para a análise dos modelos de teste. Para o PMCCF foram utilizados uma RNA e um SHG, para o PC-1D foram utilizadas 4 RNAs. A arquitetura das RNA foi a *feedforward* com uma única camada escondida e com estratégia de treinamento supervisionado baseada no algoritmo *backpropagation*. Para a RNA do modelo PMCCF, em cada neurônio foi utilizada uma função sigmoidal binária, já para as RNAs utilizadas para o modelo PC-1D a implementação da função sigmoidal utilizada foi a tangente hiperbólica. Sua topologia foi confeccionada de acordo com o descrito no capítulo 4. Esse esquema de topologia da RNA seguiu os padrões estabelecidos na literatura para minimizar a quantidade de variáveis utilizadas no processamento da RNA através da aplicação de ferramentas de análise dos dados de entrada. Esse processo permitiu que fosse possível retirar redundâncias e qualquer informação desnecessária ao processamento.

Também foi mostrado no capítulo 3 que é possível fazer uma relação onde existe uma determinada função  $G(x)$  que pode descrever o comportamento I-V da célula solar perante a sua equação característica. A existência dessa função  $G(x)$  faz com que toda a teoria de RNA possa ser aplicada no contexto do problema proposto. A complementação da técnica foi possível através da utilização de um sistema híbrido baseado em AG, onde a função de avaliação foi deixada a cargo da RNA treinada com os padrões estabelecidos. Assim, esse método de busca heurística teve como objetivo encontrar possíveis soluções do problema de forma que as melhores soluções sobre os dados processados seriam então analisadas.

A utilização da RNA como função de avaliação do AG se mostrou uma ferramenta poderosa e eficaz na solução do problema, porém mostrou também que a mesma deve ser treinada com muito cuidado para que possa refletir os dados conforme a precisão desejada. Um treinamento fraco, mensurável pela observação do erro médio quadrático elevado, faz com que os resultados expressos pela RNA e a função de avaliação do AG gerem resultados aquém dos necessários para a resolução do problema. Da mesma forma, uma RNA com treinamento excessivo (*overtraining*), mensurável pela disparidade de reconhecimento dos dados do padrão de teste, apresenta como característica a especialidade de reconhecimento somente do conjunto de dados de treinamento. Isso faz com que o AG somente consiga encontrar uma solução viável conforme os padrões de precisão estabelecidos se o mesmo estiver presente no padrão de treinamento. Portanto, observado as seguintes precauções a respeito da função de avaliação, a RNA e o SHG se mostraram eficazes na resolução dos problemas propostos.

### 6.3 Discussão sobre os resultados encontrados

Os resultados apontam para a eficácia da técnica, conforme apresentado no capítulo 5. Os resultados tanto do processamento das RNAs quanto do processamento do SHG apresentaram uma grande capacidade em aproximar os resultados referentes aos modelos determinísticos, destacando como vantagem a possibilidade da realização da simulação de análises elétricas diretamente do comportamento da célula solar e das condições de operação da mesma.

Foi observado que a técnica permite a inversão do caminho da simulação, sendo assim possível o processamento dos resultados de configuração de uma célula solar a partir de suas condições operacionais e de propriedades observáveis e mensuráveis. O sucesso dessa técnica, que representa a inversão da função  $f$  utilizada no modelo determinístico, fica bem explicitado no capítulo 5, onde os resultados obtidos foram bem próximos dos valores de configuração da célula solar. A convergência dos resultados para a solução proposta se mostrou satisfatória, onde a análise pretendia mostrar que seria possível interpretar a configuração da célula solar a partir das suas condições de operação dentro dos

parâmetros estabelecidos. A análise da densidade de corrente proveniente dos elétrons e lacunas de acordo com a profundidade da célula representa um exemplo de análise que a técnica permite produzir a partir do perfil comportamental e das condições de operação.

Decorreram desse estudo os seguintes trabalhos:

- [Mat, 2008] Matos, Fernando Barbosa; Camacho, José Roberto. Simulação da Influência dos Diferentes tipos de Dopantes no Comportamento da Homojunção de Célula Fotovoltaicas Baseadas em Silício. Revista Eletrônica de Potência. Volume 13. no. 4. p. 225-230. 2008.
- [Mat, 2007] Matos, Fernando Barbosa; Camacho, José Roberto. A model for semiconductor photovoltaic (PV) solar cells; The physics of the energy conversion, from the solar spectrum to dc electric power. ICCEP International Conference on Clean Eletrical Power. p. 352 – 359. 2007.

Trabalhos relacionados ao projeto

- [Mat, 2011] Matos, Fernando Barbosa; Camacho, José Roberto; Rodrigues, Pollyanna; Guimarães Jr., Sebastião C. A Reserch on the use of energy resources in Amazon. Renewable and Sustainable Energy Reviews. n. 15. p. 3196 – 3206. 2011.
- [Rod, 2011] Rodrigues, P.; Camacho, J. R.; Matos, B. Fernando. The application of trust method to estimate the parameters of photovoltaic modules through the use single and Double exponetial models. ICREPQ'11. International Conference on Renewable Energies and Power Quality. Las Palmas de Gran Canaria (Spain), 13<sup>th</sup> to 15<sup>th</sup> April, 2011.
- [Rod-2, 2011] Rodrigues, P.; Camacho, J. R.; Matos, B. Fernando. The trust region method applied to the extraction of parameters for photovoltaic panels. In Congresso de Métodos Numéricos em Engenharia, 2011, Coimbra.

#### Aceitos para publicação

- Matos, Fernando Barbosa; Camacho, José Roberto. Influence of concentration of dopants in the behavior of semiconductor based photovoltaic cells. Current Topics in the Electrochemistry.

#### Aguardando aceitação para publicação

- Matos, Fernando Barbosa; Camacho, José Roberto; Rodrigues, Pollyanna; Guimarães Jr., Sebastião C. The use of a deterministic model and the artificial neural network reduced model to estimate parameters through the I-V curve from physical characteristics of semiconductor based solar cells. Submetido à revista Solar Energy em setembro de 2011.

## 6.4 Conclusões

A pesquisa mostrou que para um conjunto de dados onde a célula solar possui uma configuração compatível às células comerciais encontradas no mercado, conjuntamente com possíveis configurações de cenários de operações realísticos, os resultados se mostraram um retrato descritivo expresso tanto pelos modelos determinísticos quanto pelo modelo baseado em heurísticas e ferramentas de IC.

Essa convergência entre os modelos existentes e a técnica proposta, confirmada pelos resultados experimentais, permitem validar o uso das ferramentas de IC para estimar tanto os parâmetros físicos quanto também as análises possíveis sobre a célula solar, a partir do seu comportamento e da sua condição de operação. A contribuição científica do estudo se verifica nos principais objetivos alcançados pelo projeto. São eles:

- Implantação da técnica para estimação dos parâmetros físicos da célula solar a partir das condições operacionais da mesma. Com essas estimativas, diversos parâmetros, como dopagem, tipo de dopantes, tempo de vida dos portadores minoritários, resistência de contato entre

outros podem ser estimados para células cujas características construtivas não sejam conhecidas.

- Obter as curvas de caracterização elétrica da célula solar a partir de um conjunto mínimo de parâmetros. Assim a obtenção das curvas I-V e P-V da célula solar passam a ficar independente de certos parâmetros físicos, o que permite ao modelo uma maior flexibilidade no processo de delinear a resposta da célula. Isso vai permitir a realização de simulações onde o foco está no comportamento da célula.
- Realização de análises de caracterização física e elétrica a partir do comportamento da célula solar. A simulação dessas análises é feita a partir dos parâmetros construtivos da célula solar. Com a nova técnica, essas análises poderão ser realizadas observando o comportamento operacional da célula solar, inclusive podendo verificar a degradação física e elétrica do dispositivo, tanto com o passar do tempo como também da contaminação por fatores externos.

A continuidade da pesquisa, no que se refere a trabalhos futuros, envolve a aplicação de técnica com ferramentas de IC para outras análises relacionadas à célula solar. Entre as possíveis análises estão: (1) a verificação da densidade dos portadores de acordo com a profundidade do material; (2) análise da recombinação de portadores minoritários; (3) estimativa dos parâmetros do modelo elétrico de um e dois diodos; (4) investigação da influência dos parâmetros físicos no desgaste da célula solar; (5) verificação da validade da técnica para softwares que trabalham com equações de transporte de portadores em duas (2-D) ou três (3-D) dimensões, entre outras tantas análises possíveis.

Portanto, a exploração por novos caminhos para a simulação do funcionamento da célula solar é válida no que se refere às possibilidades de análise decorrentes de um novo modelo. Com esses novos modelos, uma nova luz sobre a compreensão do funcionamento desse dispositivo é obtida. Isso favorece a busca do aperfeiçoamento e da eficiência energética tão necessária para a verdadeira popularização da utilização da energia solar fotovoltaica. Energia essa cada vez mais presente e essencial na vida do ser humano moderno.

## Referências Bibliográficas

[Abd, 2008] Abderrahmane Belghachi, Abderrachid Helmaoui. Effect of the front surface field on GaAs solar cell photocurrent. *Solar Energy Materials and Solar Cells*. n. 92. p. 667-672. 2008.

[Ade, 2007] Adel Mellit; M. Benghanem; S.A. Kalogirou. Modeling and Simulation of a Stand-Alone photovoltaic System using an Adaptive Computational Neural Network: Proposition for a new sizing procedure. *Renewable Energy*. n. 32. p. 285-313. 2007.

[Ade-1, 2008] Adel Mellit, Soteris A. Kalogirou. Computational intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*. n. 34. p. 574-632. 2008.

[Ade-2, 2008] Adel Mellit, S.A. Kalogirou. L. Hontoria, S. Shaari. Computational intelligence techniques for sizing photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*. 2008.

[Afb, 2008] A.F.B Braga, S.P. Moreira, P.R. Zampieri, J.M.G Bacchin, P.R. Mei. New Processes for the production of solar-grade polycrystalline silicon: A review. *Solar Energy Materials & Solar Cells*. n. 92. p. 418-424. 2008.

[Air, 2011] M.R. AlRashidi, M.F. AlHajri, K.M. El-Naggar, A.K. Al-Othman. A new estimation approach for determining the I-V characteristics of solar cells. *Solar energy*. n. 85. p. 1543-1550. 2011.

[And, 2009] Andres Cuevas, Jason Tan. Analytical and computer modelling of suns-Voc silicon solar cell characteristics. *Solar Energy Materials & Solar Cells*. n. 93. p. 958-960. 2009.

- [Ara, 2006] Araujo, R. de A. Neto, P. S. G. de; Petry G. G.; Ferreira, T. A. E. Uma abordagem Híbrida Inteligente Evolucionária para a previsão de Séries Temporais. Anais do XXVI Congresso da SBC. Campo Grande – MS. 2006.
- [Ash, 2008] Ashhab, Moh'd Sami S. Optimization and Modeling of a Photovoltaic Solar Integrated System by Neural Networks. Energy Conversion and Management. n. 49. p. 3349-3355. 2008.
- [Ayd, 2002] Aydinalp, Merih; Ugursal, V. Ismet; Fung, Alan S. Modeling of th appliance, lighting, and space cooling energy consumptions in the residential sector using neural networks. Applied Energy. n. 71. p. 87-110. 2002
- [Aze, 1999] Azevedo, F. M. Algoritmos Genéticos em Redes Neurais artificiais. V Escola de Redes Neurais, São José dos Campos – SP, 1999.
- [B. Das, 2000] B. Das, S.P McGinnis. Novel template-based semiconductor nanostructures and their applications. Applied Physics & Materials - Science & Processing. n. 71. p. 681-688, 2000.
- [Bae, 2009] Baek, Seung-Mook. Park Jung-Wook. RMP model based optimization of power system in multi-machine power system. Neural Networks. n. 22. p. 842 – 850. 2009.
- [Bak, 2009] Bakirci, Kadir. Models of solar radiation with hours of bright sunshine: A review. Renewable and Sustainable Energy Reviews. n. 13. p. 2580 – 2588. 2009.
- [Bar, 1993] Barron, A. R. Universal approximation bounds for superposition of a sigmoidal function, IEEE Transactions on Information Theory, IT-39, 930–945. 1993
- [Bea, 1990] Beale, R; Jackson, T. Neural Computing : an Introduction. Bristol : Adam Hilger, 1990.

[Bel, 2010] Beltrán, P. A.; Chaparro-González, F.; Pastor-Ferrando, J. P.; Rodrigues-Pozo, F. An ANP-based approach for the selection of photovoltaic solar Power plant investment projects. *Renewable and Sustainable Energy Reviews*. n. 14. p. 249 – 264. 2010.

[Bis, s.d.] Bispo JR., Esdras L.; Ferreira, Tiago, A. E. Previsão de Séries Temporais com Composição Híbrida entre Redes Neurais e Algoritmo Genético Modificado. Projeto: Previsão de Séries Temporais Utilizando Inteligência Computacional.

[Bit, 1998] Bittencourt, G. *Inteligência Computacional – Ferramentas e Teorias*. Ed. UFSC. 1ª Ed. Santa Catarina, 1998.

[Bou, 2007] Bouzidi, K.; Chegaar, M.; Nehaoua, N. New method to extract the parameters os solar cells from their illuminated I-V Curve. In 4<sup>th</sup> International Conference on Computer Integrated manufacturing, Setif, Algeria, 2007.

[Bra, s.d.] Brasil, L. et. al. Uma Arquitetura Híbrida para Sistemas Especialistas. Grupo de Pesquisas em Engenharia Biomédica (GPED) – UFSC. Santa Catarina.

[Bro, 2010] Brown, G. F.; Ager III, J. W.; Walukiewicz, W.; Wu, J. Finite Element Simulations of Compositionally Graded InGaN Solar Cells. *Solar Energy Materials & Solar Cells*. n. 94. p. 478-483. 2010.

[But, 2001] Bultman, J. H.; Burgers, A. R; Hoornstra, J.; Kinderman, R.; Koppes, M.; Soppe, W. J.; Weeber, A. W. Ideal Single Diffusion Step Selective Emitters: A Comparison Between Theory and Prattice. 17<sup>th</sup> EPVSEC. Munich 2001.

[Carb, 1998] Carbonell, J. G. *Introduction : Paradigms for Machine Learning*. [S.L. : s.n.], 1989. v. 40. p. 1 - 9.



[Car, 2008] Carrión, J. Arán; Estrella, A. Espín; Dols, F. Aznar; Toro, M. Zamorano; Rodríguez M.; Ridaio, A. Ramos. Environmental Decision-suport Systems for Evaluating the Carrying Capacity of land areas: Optimal Site Selection for Grid connected Photovoltaic Power Plants. *Renewable & Sustainable Energy Reviews*. n. 12. p. 2358-2380. 2008.

[Col, 2004] Colle, Sérgio. Abreu, L. Samuel. Rüther, Ricardo. Economic Evaluation and optimization of hybrid diesel/photovoltaic systems integrated to utility grids. *Solar Energy*. n. 76. p. 295 – 299. 2004.

[Cos, 2010] Costa, Luis H. M.; Castro, Marco A. H.; Ramos, Helena. Utilização de um algoritmo genético híbrido para operação ótima de sistemas de abastecimento de água. *Eng. Sanit Ambient*. n. 2. v. 15. p 187-196. 2010.

[Chi, 2006] Chin-Yi Tsai. Theoretical model for the optical gain coefficient of indirect band-gap semiconductors. *Jounal of Applied Physics*. n. 99. p. 053506-053506-5.2006

[Chu, 2009] Chu, A. K.; Wang, J. S.; Tsai, Z. Y.; Lee, C. K. A simple and cost-effective approach for fabricating pyramids on crystalline silicon wafers. *Solar Energy Materials & Solar Cells*. n. 93. p. 1276 – 1280. 2009.

[Clu, 1997] Clugston, Donald A.; Basore, Paul A. PC1D Version 5: 32-Bit Solar Cell Modeling on Personal Computers. 26<sup>th</sup> IEEE Specialists Conference. October. 1997.

[Cyb, 1989] G. Cybenko. Approximation by superposition of a sigmoidal function. *Math. Control and Signal Systems*. n. 2. p. 303 – 314. 1989.

[D. V. Grif, 2006] D. V. Griffiths, I. M. Smith. Numerical Methods for Engineers. Ed. Chapman & Hall/ CRC Press. 2<sup>nd</sup> ed. ISBN10: 1584884010.

[D. Gol, 1989] D. Goldberg. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley 1989.

[Din, 2008] Ding Jinlei, RadhaKrishnan Rakesh. A new method to determine the optimum load of a real solar cell using the lambert W-function. Solar Energy Materials & Solar Cells. n. 92. p. 1566 – 1569. 2008.

[Eas,1986] Easwarakhanthan, T.; Bottin, J. Bouhouch, I.; Boutrit, C. Nonlinear minimization algorithm for determining the solar cell parameters with microcomputers. International Journal of Solar Energy. n. 4. p. 1-12.1986.

[Editorial, 2008] Editorial. Reporting solar cell efficiencies in Solar Energy Materials and Solar Cells. Solar Energy Materials & Solar Cells - Elsevier. n. 92. p. 371-373. 2008.

[Editorial, 2010] Editorial. Photovoltaic, Solar Energy Materials & Thin Films – IMRC2008. Solar Energy Materials & Solar Cells. n. 94. p. 1. 2010.

[E. N. Sko, 2004] E. N. Skoundrianos; S. G. Tzafestas. Modelling and FDI of Dynamic Discrete Time Systems Using a MLP with a New Sigmoidal Activation Function. Journal of Intelligent and Robotic Systems. n. 41. p 19-36.Holanda. 2004.

[Eid, 2010] Eidelloth, S.; Eitner, U.; Steingrube, S.; Brendel, R. Open Source graphical User Interface in Matlab for two-dimensional Simulations Solving the Fully Coupled Semiconductor Equations Using COMSOL. 25<sup>th</sup> European Photovoltaic Solar Energy Conference. Valence, Spain. 06-10 September. 2010.

[Elt, 2010] Eltawil, Mohamed A. Zhao Zhengming. Grid-connected photovoltaic power systems: Technical and potential problems – A review. n. 14. p. 112 – 129. 2010.

[Eng, 2006] Engin Karapete, Mutlu Boztepe, Metin Colak. Neural network based solar cell model. Energy Conversion and Management. n. 47. p. 1159-1178. 2006.

[EPIA, 2011] Solar photovoltaic's: 2010 a record year in all respects. European Photovoltaic Industry Association. Press Release. 2011.

[F. alm, 2008] F. Almonacid, C. Rus, L. Hontoria, M. Fuentes, G. Nofuentes. Characterization of Si-crystalline PV modules by computational neural networks. Renewable Energy. 2008.

[Fer, 2005] Fernandes, A.M.R. Inteligência Computacional: noções gerais. 2 imp. Florianópolis: VisualBooks, 2005.

[Fil, s.d.] Filitto, Danilo. Algoritmos Genéticos: Uma visão Explanatória. Revista Multidisciplinar da UNIESP – Saber Acadêmico. n° 06 – 2008. ISSN 1980-5950.

[Fre, s.d.] Freeman, James A; Skapura, David M. Neural Networks Algorithms, Applications and Programming Techniques. [S.L.] : Addelfon-Wefley, 1992. p. 89 -106.

[Ger, 2002] Gergaud, O.; Multon, B.; Ahmed, H. Ben. Analysis and Experimental Validation of Various Photovoltaic Systems Models. 7<sup>th</sup> International ELECTRIMACS Congress. Montréal – Canadá. 2002.

[Gow, 1999] Gow, J. A.; Manning, C. D. Development of a photovoltaic array model for use in power-eletronics simulation studies. IEEE Proc.-Electr. Power Appl. v. 146, n. 2. 1999.

[Gur, 1999] Gurskii, A. L.; Voitikov, S. V. Quantum defect approach for the effect of electron-phonon coupling on impurity recombination in semiconductors. Solid State Communications. n. 112. p. 339 – 343. 1999.

[Hab, 2007] Habbou, A.; Chaffoui, H.; Hartiti, B. Taguchi Methodology for the optimization of  $n^+pp^+$  type Silicon Solar Photovoltaic Conversion Efficiency. The Moroccan Physical and Condensed Matter Society. n. 1. v. 9. p. 82 – 87. 2007.

[Hag, 2003] Hagenbuchner, Markus. Sperduti, Alessandro. A Self-Organizing Map for adaptive processing of structured data. IEEE Transactions on Neural Networks. vol. 14. n. 3. 2003.

[Hec, 1998] Hecht-Nielsen, R. Applications of Counterpropagation Networks. [S.L.] : Neural Networks Journal, 1988. p. 131-140.

[Heb, 1949] Hebb, D. O. The Organization of Behavior. New York: Jonh-Wiley & Sons Inc. 1949.

[Her, 2010] Hernández-Como, Noberto. Morales-Acevedo, Arturo. Simulation of hetero-junction silicon solar cells with AMPS-1D. Solar Energy Materials & Solar Cells. n. 94. p. 62-67. 2010.

[Hof, 2001] Hoffman, Joe D. Numerical Methods for Engineers and Scientists. 2<sup>a</sup> ed. Ed. Marcel Dekker, 2001.

[Hum, 2001] Hummel, Rolf E. Eletronic Properties of Materials. 3a ed. Springer 2001.

[J.A. Grow, 1999] J.A Grow; C.D.Manning. Development of a photovoltaic array model for use in power-electronics simulation studies. IEEE. Proc.-Electr. Power Appl., Vol 146, No. 2. 1999.

[Jos, 2009] Joshi, Anand S.; Dincer, Ibrahim. Reddy, Bale V. Performance analysis of photovoltaic systems: A review. Renewable and Sustainable Energy Reviews. n. 13. p. 1884 – 1897. 2009.

[K. L. Du, 2010] K. L. Du. Clustering: A Neural Network Approach. Neural Networks. n. 23.p. 89-107. 2010.

[Kin, 1997] King, David L. Photovoltaic module and array performance characterization methods for all system operation conditions. Sandia National Laboratories. NREL/SNL. U.S. Department of Energy. 1997.

[Kor, 2009] Koran, Ahmed; Sano, Kenichiro; Kim, Rae-Young; Lai, Jet-Sheng. Design of a Photovoltaic Simulator with a Novel Reference Signal Generator and Two-Stage LC output filter. IEEE Explore. p. 319-326. 2009.

[L. Zhao, 2008] L.Zhao, C.L. Zhou, H.L. Li, H.W. Diao, W.J. Wang. Design optimization of bifacial HIT solar cells on p-type silicon substrates by simulation. Solar Energy Materials and Solar Cells - Elsevier. n. 92. p. 673-681. 2008.

[Le Cun, 1989] Le Cun, Y. Generalisation and Network Design Strategies. [S.L. : s.n.]. Technical Report CRG-TR-89-4, Department of Computer Science, University of Toronto, 1989.

[Lee T., 2008] Lee, Tsung-Lin. Back-propagation Neural Network for the prediction of the short-time Storm surge in Taichung harbor, Taiwan. Engineering Applications of Computacional Intelligence. n. 21. p. 63-27. 2008

[Lin A., 2008] Lin, Albert; Phillips, Jamie. Optimization of Random Diffraction Gratingsin Thin-Film Solar Cells using Genetic Algorithms. Solar Energy Materials & Solar Cells. n. 92. p. 1689-1696. 2008.

[Lin T., 1988] Lin, Tsungnan. Horne, Bill G.; Giles, C. Lee. How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies. Neural Networks. n. 11. p. 861 – 868. 1998.

[Lip, 1987] Lippman, R. P. An Introduction to Computing with Neural Nets. IEEE ASSP Magazine, [S.L.], 1987.

[Lipi, 2003] Lipiński, M.; Panek, P. Optimisation of Monocrystalline Silicon Solar Cell. Opto-Electronics Review. n. 4. v. 11. p. 291 – 295. 2003.

[Lop, 2009] López-Rubio, Ezequiel. Multivariate Student-t self-organizing maps. Neural Networks. n. 22. p. 1432 – 1447. 2009.

[Lud, 2007] Ludwig, Jr. O.; Costa, Eduardo Montgomery M. Redes Neurais: Fundamentos e Aplicações com programas em C. Editora Ciência Moderna. Rio de Janeiro. 2007.

[M. Bas, 2005] M. Basso et. al. NARX Models of an Industrial Power Plant Gas Turbine. IEEE Explore. Transactions on Control Systems Technology. 2005.

[M.S. Ait, 2006] M.S. Ait. Cheikh, M. Haddadi, A. Zerguerras. Design of a neural network control scheme for the maximum power point tracking (MPPT) Revue des Energies Renouvelables. n. 10. p. 109-118. 2006

[Mah, 1998] Mah, Oliveira. Fundamentals of Photovoltaic Materials. NSPRI - National Solar Power Research Institute, Inc. 1998.

[Mak, 2010] Makrides, G. Zinsser, B. Norton, M. Georghiou, G. E. Schubert, M. Werner, J. H. Potential of photovoltaic systems in countries with high solar irradiation. Renewable and Sustainable Energy Reviews. n. 14. p. 754 – 762. 2010.

[Mar 1, 2006] Martins, Fernando R.; Pereira, Enio B.; Guarnieri, Ricardo A.; Yamashita, Cristina S.; Silva, Sheila A. B.; Chagas, Rafael C.; Corrá, Hugo J.; Souza, Helton P.; Abreu, Samuel Luna de. Mapeamento dos Recursos de Energia Solar no Brasil. INPE. 2006.

[Mar 2, 2006] Martins, Fernando R.; Pereira, Enio B.; Silva, Sheila A. B.; Guarnieri, Ricardo A. Variabilidade e Tendências Regionais dos Recursos de Energia Solar no Brasil. INPE. 2006.

[Mat, 2006] Matos, Fernando. B. Modelamento Computacional do Comportamento de Células Fotovoltaicas baseado nas Propriedades Físicas dos Materiais. Dissertação de Mestrado. Uberlândia. 2006.

[Mat2, 2006] Matos, Fernando B., Camacho, José R. Photovoltaic (PV) cell voltage-current characteristic based on physical properties In: Photovoltaic (PV) cell voltage-current characteristic based on physical properties. Induscon 2006. 2006, Recife.

[Mat, 2007] Matos, Fernando Barbosa; Camacho, José Roberto. A model for semiconductor photovoltaic (PV) solar cells; The physics of the energy conversion, from the solar spectrum to dc electric power. ICCEP International Conference on Clean Electrical Power. p. 352 – 359. 2007.

[Mat, 2008] Matos, Fernando Barbosa; Camacho, José Roberto. Simulação da Influência dos Diferentes tipos de Dopantes no Comportamento da Homojunção de Célula Fotovoltaicas Baseadas em Silício. Eletrônica de Potência. Volume 13. no. 4. p. 225-230. 2008.

[Mat, 2011] Matos, Fernando Barbosa; Camacho, José Roberto; Rodrigues, Pollyanna; Guimarães Jr., Sebastião C. A Reserch on the use of energy resources in Amazon. Renewable and Sustainable Energy Reviews. n. 15. p. 3196 – 3206. 2011.

[Mes, 2000] Messenger, Roger; Ventre Jerry. Photovoltaic Systems Engineering. CRC Press 2000.

[Messon, 1990] Messon, Egill; Wang, Yih-Jeou. Introduction to Computation and Learning in Computational Neural Networks. European Journal of Operational Research, North-Holand , 47, 1990. p. 1 - 28.

[Min, 2003] Ming Qu; Frank Y. Shih; Ju Jing; Hain in Wang. Automatic solar Flare Detection using MLP, RBF, and SVM. Solar Physics. Kluwer Academic Publishers. n.217. p 157-172. Holanda. 2003.

[Mit,1996] M. Mitchell, An Introduction to Genetic Algorithms. MIT Press, 1996.

[Moh, 2009] Moharil, Ravindra M. kulkarni, Prakash S. A case study of solar photovoltaic power system at Sagardeep Island, India. Renewable and Sustainable Energy Reviews. n. 13. p. 673 – 681. 2009.

[Mur, 2009] Murthy, M. V. R. A Review of new technologies, models and experimental investigations of solar driers. Renewable and Sustainable Energy Reviews. n. 13. p. 835 – 844. 2009.

[N.H. Rei, 2009] N. H. Reich; W. G. J. H. M. Van Sark; E. A. Alsema; R. W. Lof; R. E. I. Schropp; W. C. Sinke; W. C. Turkenburg. Cristalline Silicon Cell Performace at Low Light Intensities. Solar Energy Materials & Solar Cells. n. 93. p. 1471-1481. 2009.

[Nel, 2003] Nelson, Jenny. The Physics of Solar Cells. Imperial College, UK 2003.

[Nem, 2009] Nema, Pragya. Nema, R. K. Rangnekar. A current and future state of art development of hybrid energy system using wind and PV-Solar: A review. Renewable and Sustainable Energy Reviews. n. 13. p. 2096 – 2103. 2009.

[Net, 2005] Neto, Paulo S. G. de Matos. et. al. Combinação de Redes Neurais Artificiais com Algoritmo Genético Modificado para Previsão de Séries Temporais. XXV Congresso da Sociedade Brasileira de Computação – V ENIA. p. 952 – 961. São Leopoldo. 2005.



[Ome, 2008] Omer, Abdeen Mustafa. Power, People and Pollutions. Renewable and Sustainable Energy Reviews. n. 12. p. 1862 – 1889. 2008.

[Ort, 2005] Ortiz-Rivera, Eduardo I.; Peng, Fang Z. A dynamic photovoltaic system using the Z-source converter. 3<sup>rd</sup> International Energy Conversion Engineering Conference. San Francisco – USA. 2005.

[Pag, 2003] Pagliosa, Ângelo Luís. Obtenção das Funções de Pertinência de um Sistema Neuro-Fuzzy Modificado pela Rede de Kohonen. Dissertação de Mestrado. Universidade do Estado de Santa Catarina – UDESC. 2003.

[Pan, 2000] Pan, Junyou. Haarer, Dietrich. Numeric modeling of the photogeneration of free charge carriers. Chemical Physics Letters. n. 324. p. 411 – 415. 2000.

[Pat, 1999] Patel, Mukund R. Wind and Solar Power Systems. Ed. CRC Press. 1999

[Per, 2006] Pereira, Enio bueno; Martins, Fernando Ramos; Abreu, Samuel Luna; Rüther, Ricardo. Atlas Brasileiro de Energia Solar. INPE. 2006.

[Per, 1998] Pereira, Enio Bueno. Colle, Sergio. Atlas de Irradiação Solar do Brasil. LABSOLAR/NCTS. DGE/INPE. Brasília. 1998.

[Pra, 2009] Prakash, Varun Ravi; Bhat, Inder Krishnan. Energy, Economics and Environmental impacts of renewable energy systems. Renewable and Sustainable Energy Reviews. n. 13. p. 2716-2721. 2009.

[Pres, 1992] Press, William H., Saul A. Teukolsky, William T. Vetterling, e Brian P. Flannery. *Numerical Recipes in C: The Art of Scientific Computing*. 2nd ed. New York: Cambridge University Press, 1992.

[Pri, 2008] Priyanka Singh, S.N. Singh, M. Lal, M. Husain. Temperature dependence of I-V characteristics and performance parameters of silicon solar cell. *Solar Energy Materials & Solar Cells*. n. 92. p. 1611-1616. 2008.

[Res 1, 1993] Refenes, A. N. et al. Stock Performance Modeling using Neural Networks : A comparative study with regression models. London : [s.n.]. Department of Computer Sciences, University College London, 1993. p. 1 - 18.

[Res 2, 1993] Refenes, A. N. et al. Currency Exchange Rate Prediction and Neural Network Design Strategies. *Neural Computing and Applications Journal*, London, 1993. p. 46 - 58.

[Rod, 2011] Rodrigues, P.; Camacho, J. R.; Matos, B. Fernando. The application of trust method to estimate the parameters of photovoltaic modules through the use of single and double exponential models. ICREPQ'11. International Conference on Renewable Energies and Power Quality. Las Palmas de Gran Canaria (Spain), 13<sup>th</sup> to 15<sup>th</sup> April, 2011.

[Rod-2, 2011] Rodrigues, P.; Camacho, J. R.; Matos, B. Fernando. The trust region Method applied to the extraction of parameters for photovoltaic panels. In *Congresso de Métodos Numéricos em Engenharia*, 2011, Coimbra.

[Rum, 1986] Rumelhart, D. E.; Hinton, G. E.; Williams, R. J. Learning Internal Representations by Error Propagation. In : *Parallel Distributed Processing : exploration in the microstructure of cognition*. Cambridge : MIT Press, 1986.

[Sal, 2009] Salas, V.; Olias, E. Overview of photovoltaic technology status and perspective in Spain. *Renewable and Sustainable Energy Reviews*. n. 13. p. 1049 – 1057. 2009.

[Sab, 1991] Sabelfeld, K. K. Monte Carlo Methods in Boundary Value Problems. Springer-Verlag, Heidelberg, 1991, NY-Berlin.

[Sciam, 2009] Editorial. *Scientific American Brasil*. Editora Duetto. Edição Especial 2009.

[She, 2010] Sherwani A. F.; Usmani, J. A.; Varun. Life cycle assessment of solar PV based electricity generation systems: A review. *Renewable and Sustainable Energy Reviews*. n. 14. p. 540 – 544. 2010.

[Silva, 2009] Silva, Fabiano I. A.; Guerra, Sinclair M. G. Analysis of the energy intensity evolution in the Brazilian Industrial sector – 1995 to 2005. *Renewable and Sustainable Energy Reviews*. n. 13. p. 2589 – 2596. 2009.

[Sil, 1998] Silva, L. N. C. *Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais*. UNICAMP – Campinas- SP.1998.

[Sin, 2009] Singh, N. Santakrus; Jain, Amit; Kapoor, Avinashi. Determination of the Solar Cell Junction Ideality Factor using Special Trans Function Theory (STFT). *Solar Energy Materials & Solar Cells*. n. 93. p. 1423-1426. 2009.

[Sint, 2004] Sinton, R. A. Development of an In-Line Minority-Carrier Lifetime Monitoring Tool for Process Control during Fabrication of Crystalline Silicon Solar Cells. Annual Subcontract Report. Sinton Consulting, Inc. Boulder, Colorado – US. National Renewable Energy Laboratory. NREL/SR-520-35884. June 2003. Revised April 2004.

[Smi, 2000] Smiley, Eric. W. Performance modelling of building integrated photovoltaic systems. 16<sup>th</sup> European PV Solar Energy Conference, Glasgow. 2000.

[Stan, s.d.] Stangl, R.; Kriegel, M.; Schaffarzik, D.; Schmidt, M. AFORS-HET, Version 2.1. A numerical computer program for simulation of (thin film) heterojunction solar cells. Hahn-Meitner Institute Berlin (HMI), Kekuléstr. 5, D-12489. Berlin, Germany.

[Ste, 1985] Stevens, John K. Reverse Engineering the Brain. *BYTE*, [S.L.], April 1985. p. 287 - 289.

[Str, 1988] Strum, Robert D., e Donald E. Kirk. *First Principles of Discrete Systems and Digital Signal Processing*. Reading, Mass.: Addison-Wesley Publishing Company, 1988.

[Sys, 1991] SYSWERDA, G. Schendule Optimization Using Genetic Algorithms. In: DAVIS, L. Handbook of Genetic Algorithms. New York: Van Nostrand Reinhold, 1991.

[Su, 2000] Su, Mu-Chun. Chang, Hsiao-Te. Fast Self-Organizing Feature Map Algorithm. IEEE Transaction on Neural Networks. v. 11. n. 3. p. 721 – 733. 2000.

[T.B. Lud 1, 2005] T. B. Ludermir, A. C. P. L. F. Carvalho, e A. P. Braga. Computação evolutiva. In Sistemas Inteligentes: Fundamentos e Aplicações. Manole Ltda, 2005.

[T.B. Lud 2, 2005] T. B. Ludermir, A. C. P. L. F. Carvalho, A. P. Braga, e M. C. P. Souto. Sistemas inteligentes híbridos. In Sistemas Inteligentes: Fundamentos e Aplicações, p. 225–248. Manole Ltda, 2005.

[Thia, 2010] Thiaw, L.; Sow, G.; Fall, S. S.; Kasse, M.; Sylla, E.; Thioye S. A neural network based approach for wind resource and wind generators production assessment. Applied Energy. n. 87. p. 1744 – 1748. 2010.

[Thir, 2010] Thirugnanasambandam, M.; Iniyan, S.; Goic, Ranko. A review of solar thermal technologies. Renewable and Sustainable Energy Reviews. n. 14. p. 312 – 322. 2010.

[Tol, 2010] Toledo, Olga M.; Filho, Delly O.; Diniz, Antônia S. A. C. Distributed photovoltaic generation and energy storage systems: A review. Renewable and Sustainable Energy Reviews. n. 14. p. 506 – 511. 2010.

[Tsun, 2009] Tsunomura, Yasufumi; Yoshimine, Yukihiro; Taguchi, Mikio; Baba, Toshiaki; Kinoshita, Toshihiro; Kanno, Horoshi; Sakata, Hitoshi; Maruyama, Eiji; Tanaka,

Makoto. Twenty-two percent Efficiency HIT Solar Cell. *Solar Energy Materials & Solar Cells*. n. 93. p. 670-673. 2009.

[Vil, 2009] Villalva, Marcelo Gradella; Gazoli, Jonas Rafael; Rupert Filho, Ernesto. Modeling and Circuit-Based Simulation of Photovoltaic Arrays. *IEEE Xplore*. p. 1244-1254. 2009.

[Villa, 2010] Villanueva-Cab, J.; Oskam, G.; Anta, J. A. A simple numerical model for the charge transport and recombination properties of dye-sensitized solar cells: A comparison of transport-limited and transfer-limited recombination. *Solar Energy Materials & Solar Cells*. n. 94. p. 45 – 50. 2010.

[Youn 1, 1991] Youngohc, Yoon et al. Comparison of Discriminant Analysis vs Computational Neural Networks. *Journal of the Operational Research Society*, [S.L.], 44, 1991. p.52 - 55.

[Youn 2, 1991] Youngohc, Yoon; Swales, George. Predicting Stock Price Performance : A Neural Network Approach. In : *Proceedings of the IEEE 24th Annual International Conference of Systems Sciences*. [S.L. : s.n.], 1991. p. 156 - 162.

[Yu, 2009] Yu, Ting-Chung. Chien, Tang-Shiuan. Analysis and Simulation of Characteristics and Maximum Power Point Tracking for Photovoltaic Systems. *PEDS*. p. 1339 – 1344. 2009.

[Wang, 2010] Wang, Qiang. Effective Policies for renewable energy – The example of China's wind power – lessons for China's photovoltaic power. *Renewable and Sustainable Energy Reviews*. n. 14. p. 702 – 712. 2010.

[Was, 1989] Wasserman, Philip D. *Neural Computing : Theory and Practice*. New York : Van Nostrand Reinhold, 1989.

[Wu, 2009] Wu, Yuchuan. Sun, Yaqin. Lan, Qinli. Application of BP Neural Network fault diagnosis in solar photovoltaic system. IEEE – International Conference on Mechatronics and Automation. Changchun – China. 2009.

[Zhe, 2010] Zheng, Pengsheng. Tang, Wansheng. Zhang, Jianxiong. A simple method for designing efficient small-word neural networks. Neural Networks. n. 23. p. 155 – 159. 2010.

# Apêndices

## Apêndice A – Estrutura de Uma RNA e de um Algoritmo Genético

### 1- Rede Neural Artificial

#### 1.1 Camadas

Diversos são os modelos cognitivos em que uma RNA pode ser organizada. Cada modelo possui características e particularidades próprias e adequados a um determinado tipo de situação ou problema para resolução. A estrutura de uma RNA em camadas é uma importante característica topológica dos modelos cognitivos podendo a RNA conter uma ou mais camadas [Messon, 1990].

Em uma RNA estruturada em camadas existe um conjunto de vértices  $V$  conforme apresentado na Equação 3.1 nas quais estes podem ser particionados em vários subconjuntos disjuntos, onde  $V = V(0), V(1), \dots, V(n)$  de modo que as unidades de processamento da camada  $n$  somente apresentem conexões com as unidades das camadas  $n+1$  e  $n-1$ , sendo que  $n$  corresponde ao número da camada da rede neural artificial. Quando, em uma RNA a cada camada  $n$ , todos os neurônios estão conectados a camada  $n+1$ , esta recebe a denominação de *fully connected* (totalmente conectada). [Youn 1, 1991].

Uma RNA ainda pode ser classificada como sendo uma rede cíclica, também denominada de redes recorrentes. Caso não possuam circuitos fechados na sua topologia é então denominada rede acíclica. A arquitetura de uma rede neural cíclica difere da acíclica por apresentar conexões entre os neurônios pertencentes à mesma camada ou entre neurônios de camadas diferentes, cujas saídas passam a ser entradas na camada anterior. As redes recorrentes podem exibir propriedades muito similares à memória de curto prazo dos seres humanos, onde o estado da saída da rede depende em parte da entrada anterior [Lip, 1987] como pode ser observado na Figura A.1.

#### 1.2- Conexões e pesos

Os arcos (arestas) do grafo usado para representar a RNA são denominados de conexões e representam as sinapses entre os neurônios artificiais. A cada conexão no grafo está associado um peso  $w_{ij}$  que determina a importância daquela sinapse para neurônio, em analogia às sinapses de um modelo conexionista biológico humano. Essa representação determina a força de ligação entre os neurônios  $v_i$  e  $v_j$ , onde  $i$  e  $j$  correspondem à posição respectivamente nas camadas que esses neurônios ocupam na rede [Messon, 1990]. Conexões com pesos positivos, chamados excitatórios, indicam o reforço na ativação do neurônio  $v_i$ ; sinapses com pesos negativos, chamados inibitórios, indicam a inibição na ativação do neurônio  $v_i$ , de acordo com a função de ativação utilizada, ou sua nulidade caso o peso seja zero.

Assim, os neurônios artificiais, distribuídos no espaço e ligados por conexões, trocam sinais inibitórios ou excitatórios de acordo com o peso atribuído para cada conexão, permitindo que os mesmos estejam competindo ou cooperando entre si. O comportamento inteligente emerge, então, da ação simultânea dessa coletividade, sem a necessidade de elementos centralizadores [Messon, 1990].

#### 1.3- Neurônios nas camadas visíveis e nas ocultas

A interface da rede neural artificial é definida pelos neurônios de entrada  $v_i$  e unidades de saída  $v_s$ , sendo que entre essas duas pode ou não existir um número arbitrário de neurônios ocultos (hidden) em uma ou mais camadas  $v_h$ , conforme a Equação A.1 [Messon, 1990] [Youn 1, 1991].


$$V = v_i + v_s + v_h \quad (A.1)$$



O conjunto de unidades de entrada  $v_i$  e de saída  $v_s$  representam os neurônios visíveis da rede, sendo dependentes da aplicação que se quer modelar [Fre, s.d.], de acordo com a topologia implementada. Em redes neurais estruturadas em camadas, a camada de entrada é tipicamente  $v_0$  e a camada de saída,  $v_l$ .

Os neurônios das camadas ocultas  $v_h$  são utilizados para modificar os dados de entrada de modo a se obter um ganho no poder de representação dos mesmos. Isso vai permitir a RNA suportar qualquer função requerida para a entrada ou saída, de acordo com o objetivo a ser calculado [Youn 2, 1991], impondo uma representação intermediária adicional dos dados de entrada para a saída desejada.

Através dos neurônios das camadas ocultas, o modelo conexionista consegue representar abstrações que não poderiam ser diretamente realizadas a partir das unidades de entrada. O número de neurônios na camada escondida, assim como o próprio número de camadas escondidas pode variar de acordo com a finalidade e refinamento dos resultados da RNA.



**Fig. A.1: Modelos de RNA - (a)- RNA's acíclicas, (a1)- perceptron de camada simples, (a2)- perceptron de múltiplas camadas, (b) RNA's cíclicas, (b1)- RNA competitiva, (b2)-RNA SOM (Kohonen), (b3)- Modelo ART, (b4)- RNA de Hopfield.**

#### 1.4- Representação da informação na RNA

A informação que está contida no domínio do conhecimento de um problema é representada em um modelo conexionista através dos neurônios que abstraem a estrutura e o comportamento do problema a ser analisado [Bea, 1990]. Um neurônio da camada de entrada  $v_i$  possui entradas  $x_1, x_2, \dots, x_n$ , que representam os dados do domínio do problema a ser pesquisado e que correspondem aos estados dos neurônios  $v_j$ , com os quais está conectada (seja uma camada oculta ou a camada de saída).

A partir dessas entradas e do conjunto de pesos sinápticos  $w_{ij}$ , que refletem a força da unidade  $v_j$  sobre a unidade  $v_i$ , é calculado o potencial da rede (*net*) do neurônio  $v_i$ . Esse potencial na iteração  $m$  é determinado por uma regra de propagação, que geralmente equivale à soma linear da multiplicação das entradas pelos pesos somado com o valor do *bias* (tendência) do neurônio [Messon, 1990], conforme Equação A.2.

$$net_i = \sum_{j=1} w_{ij} \cdot x_j + b_i \quad (A.2)$$

Onde:

$net_i$  : Valor de saída do neurônio na camada i.

$w_{ij}$  : Valor do peso associado do neurônio i para o neurônio j.

$x_j$  : Valor de entrada para o neurônio j (estado do neurônio j).

$b_i$  : Valor do *bias* (tendência) associado ao neurônio i.

A cada iteração, o potencial determinado por  $net$  é modificado pela aplicação de uma função de ativação, determinando o estado da unidade  $vi$  na iteração  $m+1$  como apresentado na Equação A.3.

$$\begin{cases} x_i = \text{Entradas, se } i \text{ for a camada de entrada } x \leq 0 \\ x_i = net_i, \text{ se não for a camada de entrada } x > 0 \end{cases} \quad (A.3)$$

Onde:

$net_i$  : Valor de saída do neurônio na camada i.

$x_i$  : Valor de entrada para o neurônio i (estado do neurônio i).

A função de ativação corresponde a um limiar que restringe a propagação do impulso nervoso à transposição de certo nível de atividade máxima e mínima, mapeando o potencial do neurônio  $vi$  para um intervalo pré-especificado de saída [Messon, 1990]. Dentre as possíveis funções de ativação pode-se citar a linear, a rampa, a salto, a sigmóide e a tangente hiperbólica. A função linear é obtida pela equação  $g() = c.net$ , onde  $c$  é uma constante de proporcionalidade que regula a intensidade da função de ativação. A função rampa é limitada ao intervalo  $[-y, +y]$  definida pela Equação A.4, onde  $y$  representa o ponto de saturação da função.

$$\begin{cases} g() = y, \text{ se } net_i \leq -y \\ g() = net_i, \text{ se } |net_i| < y \\ g() = -y, \text{ se } net_i > y \end{cases} \quad (A.4)$$

Onde:

$net_i$  : Valor de saída do neurônio na camada i.

$y$  : Ponto de saturação da função.

A função salto admite valor +1 se o potencial do neurônio  $vi$  for positivo e -1, caso contrário. Já a função sigmóide, também conhecida por função logística, é expressa matematicamente como sendo uma função contínua, monotonicamente crescente e que gera valores graduais e não lineares no intervalo  $[0, 1]$ , como apresentado a Equação A.5.

$$g() = \frac{1}{1 + e^{-net_i}} \quad (A.5)$$

Onde:

$net_i$  : Valor de saída do neurônio na camada i.

Outra função de ativação comumente utilizada é a tangente hiperbólica [Was, 1989]. Sua curva é similar à função sigmóide, mas simétrica na origem. Essa função é frequentemente empregada por biólogos


como um modelo matemático de ativação da célula nervosa, como apresentado na Equação A.6 e na Equação A.7. A Figura A.2 apresenta os gráficos das funções apresentadas.

$$g() = \tanh() = \frac{\sinh()}{\cosh()} \quad (\text{A.6})$$

$$g() = \tanh() = \frac{e^{net_i} - e^{-net_i}}{e^{net_i} + e^{-net_i}} \quad (\text{A.7})$$

Onde:

$net_i$  : Valor de saída do neurônio na camada i.



**Fig. A.2: Gráficos da função de ativação  $g(net)$ . (a) linear, (b) rampa, (c) salto, (d) sigmóide e (e) tangente hiperbólica.**

Independente do conhecimento das funções de ativação e do comportamento de cada neurônio individual, a composição de vários neurônios distribuídos em uma ou mais camadas numa estrutura topológica de rede, manifesta reações imprevisíveis. Assim, é a reunião do estado de ativação de cada neurônio que especifica o que está sendo processado e representado na rede neural artificial em uma determinada iteração. E são essas propriedades de conjunto que determinam o interesse e a complexidade dos modelos conexionistas.

## 2 – Algoritmos Genéticos

### 2.1 - Operadores Genéticos

Para que o AG possa evoluir um conjunto de soluções para uma resposta adequada à solução do problema, são utilizados operadores inspirados nos processos de evolução e adaptação dos seres vivos na natureza, de forma a manipular os genes presentes num cromossomo. Esses operadores são baseados nos princípios da genética de forma a emular o conceito de Darwin que diz “*O mais apto sobrevive*” e manipulam

os genes de forma a permitir uma evolução do cromossomo no sentido da solução desejada para o problema. Isso por que na natureza o cruzamento entre indivíduos diferentes da mesma espécie é a forma mais eficiente de preservação do código genético. Tornando-se ao mesmo tempo possível a troca de genes de forma que os defeituosos, fracos ou até mesmo inexistentes para uma determinada característica possam ser substituídos nos futuros descendentes.

## 2.2 - Cruzamento

O operador de cruzamento tem a função de combinar os genes dos indivíduos denominados de pais para gerar novos indivíduos denominados filhos. Estes possuem um cromossomo que é formado por uma mistura de genes dos pais. Existem vários tipos de operadores de cruzamento, uns desenvolvidos para serem mais parecidos com a combinação genética presente na natureza e que tem a propriedade de serem mais genéricos para um conjunto maior de aplicação. Outros são criados de acordo com as especificações do problema alvo de forma a solucionar o problema, sendo assim mais adequados a um tipo de codificação de cromossomos. Geralmente a operação de cruzamento utiliza dois pais e cria dois novos filhos, porém a utilização de outras formas de se operar o operador de cruzamento são permitidas. Alguns dos tipos de cruzamento são apresentados a seguir.

- **Cruzamento em um ponto:** O cruzamento em um ponto consiste em dividir os cromossomos selecionados num ponto de sua cadeia, onde este ponto é escolhido aleatoriamente. Após isso, uma parte dos cromossomos de cada pai é copiada para gerar os cromossomos dos novos filhos. Assim cada filho terá uma determinada porcentagem de genes da cada pai. Geralmente utilizado quando a codificação do cromossomo é binária ou por *string* de caracteres. A Figura A.3 apresenta o cruzamento de um único ponto.

1	0	1	1	0	1	0	0	0	1		0	0	1	1	0	1	0	1	0	1
Pai 1											Pai 2									
1	0	1	1	0	1	0	1	0	1		0	0	1	1	0	1	0	0	0	1
Filho 1											Filho 2									

**Fig. A.3:Exemplo de cruzamento de cromossomos de um ponto utilizando codificação binária.**

- **Cruzamento Multiponto:** No cruzamento multiponto, um conjunto de dois ou mais pontos de cruzamento são determinados de forma que pequenas sequências de genes de cada pai sejam passadas de cada vez para cada filho de forma a promover uma maior variabilidade genética. Pode ser utilizado tanto se a codificação for binária, string de caracteres ou com genes com valores numéricos. A Figura A.4 apresenta esse tipo de cruzamento.

1	0	1	1	0	1	0	0	0	1		0	0	1	1	0	1	0	1	0	1
Pai 1											Pai 2									
0	0	1	1	0	1	0	1	0	1		1	0	1	1	0	1	0	0	0	1
Filho 1											Filho 2									

**Fig A.4:Exemplo de cruzamento multiponto utilizando codificação binária de cromossomo.**

- **Cruzamento Uniforme:** Segundo [Sys, 1991], o cruzamento uniforme consiste em gerar cada gene do descendente, copiando o correspondente gene de um dos pais, onde este gene é escolhido de acordo com uma “máscara de cruzamento” gerada aleatoriamente. No processo de criação do cromossomo percorre-se todas as posições da máscara analisando seus valores, quando o valor da posição corrente for 1, o gene do primeiro pai referente, a mesma posição da máscara é copiado. Caso o valor da máscara for 0, será copiado o gene do segundo pai. No término do processo estará gerado o novo descendente. Pode ser utilizado tanto se a codificação for binária, string de caracteres ou com genes com valores numéricos. Sua representação está presente na Figura A.5.

1	0	1	1	0	1	0	0	0	1		0	0	1	1	1	1	0	1	0	1
Pai 1											Pai 2									
1	0	0	1	0	1	0	1	0	1		1	0	1	1	1	1	0	0	0	1
Mascara											Filho									

**Fig. A.5 :Exemplo de cruzamento utilizando máscara com codificação binária de cromossomo.**

- Outros tipos de cruzamento: Dependendo das especificidades do problema a ser analisado, outras formas de cruzamento são mais utilizadas, levando-se em consideração tanto as características de codificação do cromossomo quanto às próprias características intrínsecas do problema.

### 2.3 - Mutação

À medida que os indivíduos de uma população fechada prolongam seu processo de cruzamento por muitas gerações, começa ocorrer o cruzamento entre parentes próximos. Assim, a variabilidade genética diminui, fazendo com que os indivíduos, ao se utilizar do operador de cruzamento, gerem descendentes que tenham a mesma bagagem genética dos pais, parando a evolução. Para que seja possível continuar a melhorar as soluções, no sentido da resposta final, é utilizado o operador de mutação que é responsável pela inserção de pequenas mudanças pontuais e aleatórias nos cromossomos dos filhos.

Na natureza a mutação muitas vezes é a responsável por permitir que uma determinada espécie consiga suplantar uma dificuldade imposta pelo meio ambiente, abrindo assim, a possibilidade da evolução da espécie. Como no caso dos operadores de cruzamento, existem vários tipos de operadores de mutação, os principais são:

- Mutação de bit: O operador do tipo mutação de bit é utilizado em qualquer forma de representação binária dos cromossomos. Este método gera uma probabilidade de mutação para cada bit do cromossomo. Geralmente inverte-se o bit (se 1, passa a ser 0 e se 0, passa a ser 1) conforme apresentado na Figura A.6.

1	0	1	1	0	1	0	0	0	1
Antes da Mutação									
1	0	1	1	0	1	0	1	0	1
Depois da Mutação									

**Fig A.6:Exemplo de Mutação**

- Mutação de Gene: Esse operador é utilizado quando a representação utiliza uma string de caracteres ou valores reais onde é sorteado um novo valor para a posição escolhida do cromossomo.


### 2.4 - Seleção

O operador de seleção em um algoritmo que tem como responsabilidade escolher os elementos da população que participarão do processo de reprodução (cruzamento) ou no processo de mutação, isto é, selecionar os pais dos indivíduos que estarão presentes na nova população. Esta escolha deve ser feita de tal forma que os membros da população mais adaptados ao meio ambiente tenham maior chance de reprodução, isto é, aqueles que apresentam um valor da função *fitness* mais elevado. Porém, mesmo indivíduos com um valor pequeno da função de *fitness* devem ter sua possibilidade de participarem do processo de cruzamento ou de mutação, pois podem transportar consigo uma informação genética preciosa. Dentre às formas de seleção existentes destacam-se:

- Aleatória: Os indivíduos de uma população são escolhidos aleatoriamente, independente do valor da função *fitness*, ou seja, com probabilidades iguais. Esse é o método mais parecido

com que ocorre na natureza, porém não garante que um indivíduo mais apto seja o escolhido para participar da próxima geração. Geralmente esse método emprega o elitismo, ou seja, o indivíduo mais apto de uma geração é perpetuado para uma próxima geração fazendo com que suas chances de participar de um cruzamento cresçam com o passar das iterações.

- Torneio: Também é um tipo de método bastante comum na natureza, onde indivíduos competem para participar do operador de cruzamento. Assim um pequeno conjunto de indivíduos (geralmente entre 3 ou 4 indivíduos) são escolhidos aleatoriamente, mas somente os dois com maior aptidão (*fitness*) irão participar do cruzamento. Geralmente também é utilizado o método do elitismo.
- Monte Carlo: É a forma mais conhecida de se fazer a seleção dos indivíduos segundo [Fer, 2005]. Também é conhecido como algoritmo de seleção por roleta, onde cada indivíduo da população ocupará uma porção da roleta que é proporcional ao seu índice de aptidão (*fitness*). Com isto os indivíduos que possuem uma alta aptidão ocuparão uma porção maior da roleta do que os indivíduos que possuem uma aptidão menor, tendo portanto, uma probabilidade maior de serem escolhidos, principalmente para o operador de cruzamento. Esta roleta é girada várias vezes, onde a quantidade de giros varia conforme a dimensão da população. Em cada giro da roleta é selecionado um indivíduo que participará do processo de geração da nova população [Sab, 1991]. A Figura A.7 apresenta a seleção pelo método Monte Carlo.



**Fig A.7: Representação da escolha pelo método de Monte Carlo**

## 2.5 - Execução do AG

A execução do algoritmo genético se dá inicialmente pela definição de alguns parâmetros. Entre eles destacam-se o tamanho da população, taxa de mutação, elitismo, número máximo de iterações e um valor para o erro referente à função *fitness*. O AG é um algoritmo iterativo onde os procedimentos de cruzamento, mutação, seleção e avaliação são repetidos até o término do número de iterações ou do padrão de erro determinado.

Outra função que é utilizada no AG é referente à validação dos cromossomos gerados, tanto na fase inicial do programa, quanto nos processos de cruzamento e mutação. Isso, por que alguns genes podem determinar somente algumas faixas de valores permitidos para a resolução do problema, de acordo com as características do problema. Essa função pode ser utilizada de duas maneiras:

- Função de avaliação independente: Os cromossomos são gerados livremente e aleatoriamente no processo de criação ou através dos operadores de cruzamento e mutação. A função de avaliação então verifica a validade do cromossomo, caso esse gere um indivíduo inválido para a solução do problema, um novo indivíduo deve ser gerado. Esse processo se assemelha mais ao processo natural, onde indivíduos inválidos são geralmente

abortados. Esse meio de avaliação é o mais viável se o espaço de busca para uma solução variar com o tempo, como por exemplo, num jogo de xadrez.

- Função de avaliação integrada ao processo de criação: O processo de criação, cruzamento ou mutação já incorporam dentro das suas rotinas regras fixas para a criação de indivíduos válidos, independente do operador aplicado ou momento de execução do AG. Como o AG é uma heurística com características estocásticas, sua solução não representa uma resposta determinística com a melhor solução para o problema, mas garante que a solução encontrada está num limiar próximo de um ponto ótimo, separado por uma margem de erro geralmente determinada na configuração inicial do programa. No Apêndice - C é apresentado o algoritmo de execução do AG.

## Apêndice B – Principais algoritmos utilizados no processo de treinamento da RNA.

### 1- Principais algoritmos utilizados no treinamento supervisionado

O primeiro algoritmo de treinamento supervisionado refere-se a RNA baseada em perceptrons que tem sua atuação em conjuntos de treinamento linearmente separáveis. Essa topologia permite a inclusão do *bias*. No algoritmo de aprendizagem do perceptron baseado na regra Hebb, busca-se um vetor  $W$  que tenha projeção positiva com todos os exemplos positivos e projeção negativa com todos os exemplos negativos, o que é denominado produto interno [Sil, 1998]. A aprendizagem do perceptron apresenta sucesso em tempo finito para um conjunto de treinamento finito e separável de exemplos de treinamento. O algoritmo de treinamento do perceptron pode ser implementado conforme o Algoritmo B.1.

#### Algoritmo 1: Algoritmo de treinamento do perceptron

---

```

001: 1. Fazer  $W$  ser o vetor nulo.
002: 2. Selecionar um exemplo de treinamento  $x_k$  (com a correspondente classificação
003:  $ck$ ). Isto pode ser feito de maneira cíclica (em ordem) através dos exemplos de
004: treinamento ou pegando um exemplo aleatoriamente.
005: 3. Se  $W$  classifica  $x_k$  corretamente, isto é, se:  $W \cdot x_k \geq 0$  e  $Ck = +1$  ou se  $W \cdot x_k < 0$  e
006:  $ck = -1$ , então, não fazer nada. Senão passo de alteração: Modificar  $W$  somando
007: ou subtraindo  $x_k$  de acordo com a saída correta ser  $+1$  ou  $-1$ :  $W' = W + Ck \cdot x_k$ .
008: 4. Ir ao passo 1.

```

---

Logo para um conjunto de dados finitos de treinamento  $x$ , com componentes inteiros ou racionais, dependendo da função de ativação utilizada no neurônio; o algoritmo de aprendizagem do perceptron irá produzir num tempo finito um vetor peso que satisfaça todos os exemplos de treinamento, se e somente se os dados presentes no padrão de entrada forem linearmente separáveis, caso contrário uma solução não será alcançada.

Se um conjunto de exemplos de treinamento  $x$  é denominado como não linearmente separável, então, por definição não existe um vetor de pesos  $W$  que classifique corretamente todos os exemplos de treinamento em  $x$  utilizando o algoritmo de aprendizagem do perceptron. A alternativa mais natural é encontrar um vetor de pesos  $W^*$  que classifique tantos exemplos de treinamento quanto possível de  $x$ .

Embora o algoritmo de aprendizagem do perceptron possa classificar um conjunto de dados linearmente separáveis, ele tem comportamento denominado pobre ou fraco. Isso por que se o algoritmo é terminado, mesmo após um grande número de iterações, não se tem garantia da qualidade dos pesos que são produzidos, ou seja, não se pode afirmar que os pesos encontrados são os melhores para a solução do problema. Isso se deve ao fato de que o mesmo usa somente reforço negativo, ignorando totalmente os exemplos que são corretamente classificados.

Outro tipo de RNA que utiliza treinamento supervisionado é denominado de Máquina linear. Também é denominado de grupos de escolha. As Máquinas lineares generalizam os modelos de célula única e são úteis para problemas de reconhecimento de padrões onde a entrada deve ser colocada em uma de várias classes. Para cada conjunto de entradas, somente uma célula do grupo está com sua saída ativa, enquanto que todas as outras estão inativas. Devido a esta característica também são indicadas para problemas de detecção de faltas, onde for assumido que somente uma falta possa ocorrer na unidade de tempo.

Na Máquina linear calcula-se a soma ponderada para cada célula do grupo e define-se a célula que se torna ativa como sendo aquela cuja soma ponderada seja a maior de todas, conforme apresentado na Equação B.1.



$$S_i = \sum_j w_{ij} \cdot y_j \quad (\text{B.1})$$

Onde:

$S_i$  : Somatório dos pesos e saída da rede.

$w_{ij}$  : Peso do arco que liga o neurônio  $i$  ao neurônio  $j$ .

$y_i$  : saída calculada pelo neurônio  $j$ .

O resultado de  $S_i$  é representado por  $u$  e está presente na Equação B.2.

$$u = \begin{cases} +1, & \text{se } S_i > S_k \ \forall k \neq i \\ -1, & \text{se } \exists S_i < S_k \\ 0, & \text{caso contrário} \end{cases} \quad (\text{B.2})$$

Se duas ou mais células obtiverem a soma máxima, então elas terão ativação com valor zero (ou desconhecido). Estes grupos de células também são denominados de grupos de escolha porque exatamente uma célula do grupo será selecionada. O algoritmo de treinamento das Máquinas Lineares pode ser gerado da seguinte maneira:

#### Algoritmo 2: Algoritmo de Máquinas Lineares

---

```

001: 1. Faça o conjunto de pesos  $w = \langle 0, 0, \dots, 0 \rangle$ ,  $S_k$ ,  $ncorretos$ ,  $wcorretos = 0$ 
002: 2. Pegue aleatoriamente um exemplo de treinamento  $x^k$  (com sua correspondente
003: classificação  $c^k$ ).
004: 3. Se  $w$  classifica corretamente  $x^k$ , isto é, se a classe correta é  $i$  e  $w_i \cdot x^k > w_j \cdot x^k$  para
005:  $i \neq j$ , então:
006: (a)  $s = s + 1$ 
007: (b) Se  $s > S_w$ , então:
008: (c) Calcular  $ncorretos$  testando todos os exemplos de treinamento
009: (d) se  $ncorretos > wcorretos$ , então:
010: i.  $W = w$ 
011: ii.  $S_w = s$ 
012: iii.  $wcorretos = ncorretos$ 
013: iv. Se todos os exemplos de treinamento são corretamente classificados, finalizar,
014: caso contrário:
015: Passo de alteração: Formar um novo vetor de pesos. Selecionar  $j \neq i$  que satisfaça
016:  $w_i \cdot x^k \leq w_j \cdot x^k$  e atualizar os pesos das células  $i$  e  $j$ , conforme a Equação B.3 e a
017: Equação B.4
018:  $w_i = w_i + x^k$  (B.3)
019:  $w_j = w_j - x^k$  (B.4)

```

---

Outra proposta de treinamento supervisionado é a partir da regra Delta utilizada no *Adaline* ou Máquina não linear. Seu aprendizado é baseado no erro observado no neurônio de saída em comparação com a resposta esperada no vetor de treinamento. O *Adaline* permite algumas variações de acordo com as especificidades do problema, permitindo a elaboração de algoritmos construtivos. O conceito que envolve esses algoritmos construtivos é a simplificação do problema onde o objetivo é transformar o treinamento em um problema simples de aprendizagem de uma célula.

## 2- Principais algoritmos utilizados no treinamento não supervisionado

O treinamento não supervisionado é aplicado em RNA's cíclicas, onde a competição entre os neurônios de saída e adaptabilidade são as principais características desse modelo. A competição por recursos é uma maneira de diversificar e otimizar a função dos elementos de um sistema distribuído. Isso conduz à melhoria em nível local sem controle global para assinalar recursos do sistema de redes competitivas que recebem informação idêntica das entradas, mas competem pelos recursos através de conexões laterais na topologia ou pela formulação da regra de aprendizagem, permitindo que se especializem em áreas diferentes da entrada. A rede competitiva de Kohonen [Su, 2000] é um representante dessa estratégia de treinamento. Esse tipo de treinamento é intrinsecamente uma operação não-linear onde se destacam dois tipos básicos de estratégia de funcionamento. São eles:

- *Hard*: somente um neurônio na camada de saída ganha os recursos.
- *Soft*: há um vencedor, mas seus vizinhos também recebem uma parte dos recursos.

Uma rede competitiva típica consiste de uma camada de neurônios, todos com a mesma entrada. O neurônio com melhor saída é o vencedor. O objetivo da aprendizagem competitiva é criar uma regra de aprendizagem que possa ser aplicada a uma topologia de camada única e que atribua aos neurônios de áreas diferentes do espaço de entrada. O neurônio mais próximo da entrada atual deve vencer a competição, portanto é necessária uma medida de proximidade para avaliar qual é o neurônio vencedor. O produto interno é um bom indicador para essa mediada, pois é sensível, não somente às direções, mas também ao comprimento dos vetores, isto é, a entrada e os pesos devem ser normalizados.

Usando a regra competitiva, uma rede linear de camada única agrupa e representa os dados que residem em uma vizinhança do espaço de entrada. Cada vizinhança é representada por um único neurônio onde os pesos de cada neurônio representam pontos no espaço de entrada chama dos vetores protótipos. Se os vetores forem unidos por uma linha e forem traçadas perpendiculares na metade de cada uma, as mesmas se encontrarão e formarão uma estrutura semelhante a uma colméia de abelhas. O processo de agrupamento é uma transformação do espaço contínuo para o discreto, onde do ponto de vista teórico, agrupamento é uma forma de estimação não-paramétrica de densidade. Como agrupamento é não-supervisionado, ele não pode ser usado diretamente para classificação, em várias aplicações práticas, os dados de cada classe tendem a ser densos e, portanto, há um vale natural entre as classes. Nestes casos o agrupamento pode ser um pré-processador para a classificação, com isto obtém-se redes de classificação mais simples.

A rede SOM de Kohonen (mapas auto-organizáveis) realiza um mapeamento de um espaço contínuo de entrada para um espaço discreto de saída, onde as propriedades topológicas da entrada são preservadas. A rede SOM de Kohonen é uma rede linear de camada única totalmente conectada, cuja saída é organizada em uma ou duas dimensões. Quando a SOM se adapta às entradas de altas dimensões, ela deve se estender e enrolar para cobrir o espaço de entrada [Hag, 2003][Lin T., 1988].

Outro tipo de rede que faz uso da estratégia de aprendizado não supervisionado é denominado *Learning Vector Quantization* ou redes LVQ que fazem uso de informações de classes para ajustar os limites das regiões de seleção. Se a regra competitiva produz a saída certa, não há alteração; se a saída estiver errada, os pesos dos neurônios devem ser repelidos do agrupamento atual, conforme a Equação B.5.

$$\Delta w_{ij} = \begin{cases} \eta(x_j + w_{ij}) & \text{se a classe estiver correta} \\ \eta(x_j - w_{ij}) & \text{se a classe estiver errada} \end{cases} \quad (\text{B.5})$$

Onde:

$w_{ij}$  : Valor do peso sináptico entre os neurônios i e j.

$\Delta w_{ij}$  : Valor de atualização do peso.

$\eta$  : Taxa de Aprendizagem.

Da mesma forma as RNA's denominadas rede ART *Adaptive Resonance Theory* também utilizam uma estratégia de aprendizado não supervisionado. A rede mapeia os dados de entrada em padrões de saída, assim essa arquitetura pode ser usada para descoberta de grupos se a resposta desejada torna-se a entrada,  $d(n) = x(n)$  e a saída do sistema torna-se a camada competitiva.

### 3- Aprendizado pela Retro propagação do erro

Tanto a regra Hebb quanto a regra Delta se aplica às RNA's sem camadas escondidas, ou denominadas de RNA's de camada simples. Para RNA's de múltiplas camadas o treinamento exige um método mais elaborado. A retro propagação do erro ou *Backpropagation* pode ser considerada como uma generalização da Regra Delta para redes diretas com mais de uma camada, onde ao menos uma camada de neurônios não está envolvida com a entrada ou saída. Ou seja, existe pelo menos uma camada extra denominada oculta ou interna a RNA.

O algoritmo *Backpropagation*, proposto por Werbos, Parker e Rumelhart, é o algoritmo de aprendizado mais largamente utilizado para redes acíclicas de múltiplas camadas [Messon, 1990] [Res 2, 1993]. Ao se apresentar um determinado padrão de entrada a uma rede neural não treinada e o respectivo padrão de saída, uma saída aleatória é produzida a partir dos pesos iniciais presentes em cada conexão sináptica juntamente com o *bias*. A partir da saída produzida pela rede é calculado um erro, representando a diferença entre o valor obtido e o desejado.

O objetivo do algoritmo consiste, então, em reduzir continuamente o erro calculado pelo gradiente descendente até um determinado valor aceitável ou até que um determinado número de iterações seja atingido. Isto é alcançado pelo ajuste dos pesos entre as conexões dos neurônios pela aplicação da regra Delta Generalizada, que calcula o erro para algum neurônio particular e propaga esse erro para a camada anterior. Cada neurônio tem seus pesos ajustados de modo a minimizar o erro da rede.

A minimização do erro no algoritmo *Backpropagation* é obtida pela execução do gradiente descendente na superfície de erros do espaço de pesos, onde a altura para qualquer ponto no espaço de pesos corresponde à medida do erro.

O ajuste dos pesos inicia nos neurônios de saída, onde a medida do erro está disponível, e procede com a retro propagação desse erro entre as camadas, ajustando os pesos até que a camada dos neurônios de entrada tenha sido processada.

Para as unidades de saída, como são conhecidos os valores desejados e obtidos, o ajuste dos pesos sinápticos é relativamente simples; para as unidades das camadas ocultas, o processo é diferente. Os pesos para um neurônio particular devem ser ajustados na proporção direta ao erro da unidade de processamento a qual está conectado. Essa é a razão pela qual a retro propagação dos erros através da rede permite o correto ajuste dos pesos sinápticos entre todas as camadas do modelo conexionista.

Assim, é possível identificar duas fases distintas no processo de aprendizagem do *Backpropagation*: aquela onde as entradas se propagam entre as camadas da rede, da camada de entrada até a camada de saída, e aquela em que os erros são propagados na direção dos neurônios de saída para os neurônios de entrada.

### 3.1- Etapas do Algoritmo *Backpropagation*

O cálculo dos pesos e *bias* é necessário sempre que a saída desejada  $y_j$  e a saída real  $d_j$  não forem coincidentes, ou estejam acima de um valor de erro máximo pré estabelecido. A atualização é feita pela aplicação do método gradiente decrescente, conforme a Equação B.6.

$$w_{ij} = w_{ij} + \Delta w_{ij} \quad (\text{B.6})$$

Onde:

$w_{ij}$  : Valor do peso sináptico entre os neurônios  $i$  e  $j$ .

$\Delta w_{ij}$  : Valor de atualização do peso.

O valor de  $\Delta w_{ij}$  é determinado pelo gradiente decrescente conforme a Equação B.7.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (\text{B.7})$$

Onde:

$\Delta w_{ij}$  : Valor de atualização do peso.

$w_{ij}$  : Valor do peso sináptico entre os neurônios  $i$  e  $j$ .

$E$  : Erro médio quadrático.

$\eta$  : Taxa de aprendizagem da rede neural.

O algoritmo B.3 apresenta as etapas do processamento do *Backpropagation*.

Os padrões de treinamento são apresentados sucessivamente às unidades visíveis da rede neural artificial, até que um erro aceitável seja alcançado ou enquanto um número determinado de iterações não for satisfeito. A taxa de aprendizado tem grande influência na forma que a rede neural caminha para a solução dos *bias* e pesos sinápticos corretos. Sendo que se a taxa de aprendizagem for muito pequena, a convergência será muito lenta, podendo não atingir o resultado esperado por falta de energia cinética suficiente para superar um mínimo local. Da mesma forma, se a taxa de aprendizagem for muito grande pode ocasionar oscilações no processo de funcionamento da rede neural, fazendo com que a mesma não alcance o resultado esperado.

A inclusão do termo denominado *momentum* tem por objetivo aumentar a velocidade de treinamento da rede neural, reduzir o perigo de instabilidade causada por oscilações no cálculo dos pesos e *bias* e também impedir que a RNA caísse numa região de mínimo local; esta medida impediria sua parada antes da convergência correta dos pesos. Este termo pode ou não ser utilizado durante o treinamento e seu valor varia de 0.0 (não utilização) a 1.0, o que altera a Equação B.10, conforme apresentado pela Equação B.11 e apresentado pela Figura B.1. O *momentum* permite a conservação da direção da evolução do peso de uma iteração para outra. Esse mecanismo amorteceria mudanças bruscas nos pesos na evolução da RNA.

O último conjunto de pesos e *bias* observado entre as conexões das células é mantido para testar a habilidade da rede em mapear a função de entrada para saída e a consequente validação do modelo de redes neurais artificiais [Fre, s.d.]. Caso os resultados sejam insatisfatórios, um novo processamento deve ser realizado alterando-se principalmente a taxa de aprendizado, o número de iterações e até a topologia da rede, aumentando o número de neurônios na camada escondida e o número de camadas.

O desempenho do algoritmo de aprendizagem *Backpropagation* está condicionado à modelagem adotada na rede neural artificial, principalmente no que se refere a sua topologia, que varia de acordo com as especificidades do problema a ser solucionado. Da mesma forma, o conjunto de dados utilizados tem impacto direto no resultado do processamento da rede neural, sendo que é necessário fazer um tratamento nos dados antes de utilizá-los.

### Algoritmo 3: Algoritmo *Backpropagation*

---

```

001: 1. Inicializar o conjunto de pesos  $W$  com valores pequenos e aleatórios;
002: 2. Apresentar o vetor de entrada e o vetor de saída do padrão de treinamento;
003: 3. Calcular a resposta da rede;
004: 4. Calcular o erro para as unidades de saída por meio da Equação B.8.
005:  $\delta_i = g'(net_i) \cdot (d_j - y_i)$  (B.8)
006: //Onde:  $\delta_i$ : Valor do erro para a unidade de processamento de saída.
007: //  $g'(net_i)$ : Valor da derivada da função de ativação do neurônio  $i$ .
008: //  $d_j$ : saída esperada para o neurônio conforme padrão de treinamento.
009: //  $y_i$ : saída da rede calculada com os pesos atuais.
010: 5. Calcular o erro para as unidades ocultas conforme a Equação B.9.
011:  $\delta_i = g'(net_i) \cdot \sum \delta_k \cdot w_{ki}$  (B.9)
012: //Onde:  $\delta_i$ : Valor do erro para o neurônio  $i$ .
013: //  $g'(net_i)$ : Valor da derivada da função de ativação do neurônio  $i$ .
014: //  $\delta_k$ : Valor do erro para o neurônio  $k$ .
015: //  $w_{ki}$ : Valor do peso do neurônio  $k$  para o neurônio  $i$ .
017: 6. Atualizar os pesos de todas as camadas conforme a Equação B.10.
018:  $\Delta w_{ij} = \eta \delta_i \cdot y_j$  (B.10)
019: //Onde:  $\Delta w_{ij}$ : Valor de atualização do peso.
020: //  $\eta$ : Taxa de aprendizagem da rede neural.
021: //  $\delta_i$ : Valor do erro para o neurônio  $i$ .
022: //  $y_j$ : Valor de saída do neurônio  $j$ .

```

---

$$\Delta w_{ij} = \eta \delta_i \cdot y_j + \rho \Delta w_{ij} \quad (B.11)$$

Onde:

$\Delta w_{ij}$ : Valor de atualização do peso.


$\Delta w_{ij}$ : Valor de atualização do peso da iteração anterior.

$\eta$ : Taxa de aprendizagem da rede neural.

$\delta_i$ : Valor do erro para o neurônio  $i$ .

$y_j$ : Valor de saída do neurônio  $j$ .

$\rho$  : Fator momentum.



**Fig. B.1: Comparativo da utilização do *momentum* no processamento da RNA**

Alguns problemas podem ocorrer durante o processamento da RNA que utiliza o algoritmo *Backpropagation* como:

- Parada da rede: Se os pesos forem ajustados em valores muito grandes a ativação se torna zero ou um e os ajustes passam a ser nulos, parando a rede.
- Mínimos locais: A superfície de erro de uma rede complexa é cheia de montanhas e vales. Desta forma, a mesma pode ficar presa em um ponto de mínimo local impedindo que o resultado correto seja alcançado.

O número  $N$  mínimo de padrões de treinamento requerido para classificar exemplos de teste com um erro aceitável em uma rede com um total de  $W$  pesos é indicado pela Equação B.12.

$$N > \frac{W}{\delta} \quad (\text{B.12})$$

Onde:

$N$  : número de elementos presentes no vetor de treinamento.

$W$  : Quantidade de pesos presentes de acordo com a topologia da RNA.

$\delta$  : Erro máximo permitido para o problema.

Assim, pode-se considerar que pela quantidade de dados apresentados a RNA possui uma boa representatividade do universo considerado. Outro método para se conseguir a representatividade necessária é por meio do pré-processamento dos dados de entrada de forma a reduzir dimensionalidade topológica da RNA. Para grandes conjuntos de treinamento, o erro no MLP usando o algoritmo *Backpropagation* é independente do tamanho do espaço de entrada e é escalar com o inverso do número de neurônios escondidos. Observa-se também que o tempo de treinamento de MLP com retro propagação aumenta exponencialmente com o tamanho do problema e com o aumento no número de neurônios e camadas escondidas [Bar, 1993].

## Apêndice C – Algoritmo de Execução de um AG

### Algoritmo 4: Algoritmo de Execução de um AG

---

001:	1. Inicialize o sistema com o valor da população, taxa de mutação, tipo de elitismo, número máximo
002:	de iterações e valor do erro máximo;
003:	2. Gere aleatoriamente os cromossomos da população para cada indivíduo presente na população;
004:	3. Verifique a validade dos indivíduos gerados;
005:	4. Avalie os indivíduos da população pela função <i>fitness</i> .
006:	5. Enquanto não for atingido o número e iterações ou o erro máximo repita os passos de 1 a 4:
007:	6. Enquanto não for atingido o número máximo da população repita:
008:	6.1. Escolha dois indivíduos a partir do operador de seleção;
009:	6.2. Utilize o operador de cruzamento;
010:	6.3. Verifique a validade dos indivíduos gerados.
011:	6.4. Coloque os novos indivíduos gerados na nova população;
012:	7. Escolha os indivíduos a serem mutados da nova população de acordo com a taxa de mutação;
013:	8. Verifique a validade dos indivíduos gerados na mutação.
015:	9. Para cada indivíduo da nova geração avalie os indivíduos da população pela função <i>fitness</i> .
016:	10. Selecione os indivíduos com melhor <i>fitness</i> para participar da nova geração para nova avaliação.

---

## Apêndice D – Sistemas Híbridos

### 1 - Integração de Sistemas Híbridos

Diversas são as formas para realizar a integração de Sistemas Híbridos, a forma e a escolha são geralmente determinadas pelas características do problema a ser analisado. Porém algumas técnicas tradicionais de IC são combinadas para formar o SH. Destacam-se [Bra, s.d.]:

- Árvores de decisão (IDT - *Induction of Decision Trees*);
- Sistemas baseados em conhecimentos (KBS - *Knowledge Based Systems*);
- Sistemas especialistas (Expert Systems);
- Sistemas baseados em regras (*Rule Based/Production Systems*);
- Sistemas baseados em regras de lógica difusa ou nebulosa (*Fuzzy Logic rules*);
- Sistemas baseados em conhecimentos, aquisição de conhecimentos do tipo ILP (*Inductive Logic Programming*);
- Sistemas baseados em casos/exemplos (CBR – *Case Based Reasoning*);
- Algoritmos Genéticos (AG - *Genetic Algorithms*);
- Redes Neurais Artificiais (RNA - *Computacional Neural Networks*);

Estes métodos têm sido usados de forma combinada, dando origem a múltiplos sistemas híbridos como:

- **Sistemas Simbólico-Genéticos:** Estes sistemas são normalmente compostos de um módulo genético (AG) responsável pela aquisição de conhecimentos a partir dos dados disponíveis sobre um problema (como exemplos de aprendizado, regras de formação, estados de operação, etc), e de um módulo simbólico responsável pela implementação do mecanismo de inferência simbólica (*inference engine*). O AG vai utilizar os operadores genéticos a partir de uma base de regras, visando otimizá-las em relação a uma base de dados disponível. A base final de regras obtidas é então manipulada por um módulo simbólico para apresentação do resultado final [Bis, s.d.][Net, 2005].
- **Sistemas Neuro-Genéticos:** A maior parte das aplicações que envolvem a utilização de sistemas neuro-genéticos tem como finalidade contornar os problemas relativos à escolha de uma arquitetura de uma RNA adequada para um determinado problema. A utilização desse SH visa estimar e otimizar a escolha dos parâmetros de configuração utilizados no processo de aprendizado pela RNA. Uma RNA que se utiliza de AG para modificar a sua estrutura em tempo de processamento, é denominada de redes evolutivas [Bis, s.d.][Net, 2005]. Esses sistemas Neuro-Genéticos também podem ser configurados de outras maneiras, como a utilização do AG para otimização dos pesos sinápticos da RNA ou da utilização da RNA como função de avaliação (*fitness*) do AG.
- **Sistema Neuro-CBR:** A integração de uma RNA e de um sistema baseado em casos permite, onde existem dois objetivos específicos: 1- Criar generalizações sobre um conjunto de exemplos de um problema. 2 – Preservar as particularidades relacionadas a este problema. Assim, os Sistemas Neuro-CBR buscam um compromisso entre a generalização total e a especialização individual em relação a uma base de exemplos. Neste SH fica evidenciado a complementaridade entre os métodos que compõem o sistema, o que permite que ambos ajudem a suprir as deficiências de um método em relação ao outro. Os sistemas neuro-CBR também podem ser classificados dentro da categoria de “sistemas neuro-simbólicos”.
- **Sistemas Neuro-Simbólicos:** Nesta categoria estão todos os sistemas híbridos que combinam a representação de conhecimentos em uma forma simbólica (representação de alto nível, compreensível para o ser humano) e a representação de conhecimentos em uma forma conexionista (RNA), ou, como também é conhecida, representação sub-simbólica (representação de baixo nível de compreensão extremamente difícil para um ser humano).



## 2 - Estrutura do Cromossomo do SHG

A sistemática de elaboração do Sistema híbrido inicia-se a partir da definição do modelo de cromossomo utilizado no AG. Essa estrutura deve permitir tanto à função de avaliação realizar diretamente o processamento do valor de aptidão de cada indivíduo como representar a resposta do problema proposto. Como a função de avaliação é uma RNA, cuja mesma utiliza a função sigmóide em cada neurônio, os valores utilizados devem ser compatíveis com os valores de entrada esperados, ou seja, serem valores reais e compreendidos no intervalo  $[0,1]$ , conforme preparação apresentada no capítulo 4. Cada cromossomo deve conter os dados necessários para sua avaliação, são eles: iluminação, temperatura, área, concentração tipo N, concentração tipo P, corrente e tensão no ponto de potência máximo, tensão em circuito aberto e corrente em curto-circuito.

Como apresentado no capítulo 4, a representação da concentração dos dopantes é dividida em duas partes: uma para identificar simbolicamente a concentração numa escala variando de  $1 \times 10^0$  a  $9 \times 10^0$  e a ordem de grandeza, de acordo com o modelo estudado, numa ordem que varia de  $10^{13}$  a  $10^{16}$ .

## 3 - Geração da População

O SHG deve, a partir da definição do tipo de cromossomo a ser utilizado, construir uma população de soluções para o problema determinado. Três abordagens, nesse sentido, podem ser tomadas:

- Podem-se gerar aleatoriamente todos os genes do cromossomo e criar uma função de validação para verificar quais indivíduos (cromossomos) representam uma solução factível para o problema.
- Podem-se gerar aleatoriamente todos os genes do cromossomo, porém permitindo que somente sejam criados os indivíduos que representem um indivíduo válido, ou seja, embutir na função de criação um conjunto de regras observadas no capítulo 4 da definição dos dados, permitindo que somente genes válidos sejam atribuídos ao cromossomo.
- Podem-se ler os dados referentes à operação da célula solar que se deseja observar, de forma que um determinado valor de corrente e tensão no ponto de potência máximo,  $V_{oc}$  e  $I_{sc}$  estejam relacionados a uma condição específica de iluminação, temperatura e área da célula solar. Os demais genes serão gerados aleatoriamente, porém permitindo que somente sejam criados os indivíduos que representem uma solução factível, ou seja, embutindo na função de criação um conjunto de regras descritas no capítulo 4 da definição dos dados. Determinando assim, que somente genes válidos sejam atribuídos ao cromossomo.

A terceira abordagem foi a escolhida por permitir verificar, através de um conjunto de medições realizadas, os parâmetros de construção da célula solar. Assim o SHG lê de um arquivo os dados referentes à iluminação, temperatura, área da célula, corrente e tensão no ponto de potência máxima, tensão em circuito aberto e corrente de curto-circuito, colocando esses dados respectivamente nos campos (a),(b),(c),(j),(k),(l),(m) do cromossomo, como apresentado na Figura D.1.

Os demais dados são criados aleatoriamente conforme a descrição dos dados presentes no capítulo 4, seguindo as seguintes normas:

- Campo (d): Tipo de dopante N. Pode conter os valores 0,000 (As); 0,500 (Sb) ou 1,000 (P). Esse campo apresenta uma representação simbólica dessa propriedade.
- Campo (e): Concentração do dopante tipo N. Pode conter um valor compreendido entre 0,1 a 0,9. Esse campo representa o valor normalizado para essa propriedade que varia de 1 a 9.
- Campo (f): Ordem de grandeza do dopante tipo N. Pode conter os valores 0,000 ( $10^{13}$ ); 0,333 ( $10^{14}$ ); 0,666 ( $10^{15}$ ); 1,000 ( $10^{16}$ ). Esse campo representa o valor simbólico para essa propriedade.
- Campo (g): Tipo de dopante P. Pode conter os valores 0,000 (B); 0,300 (Al); 0,600 (Ga); 1,000 (In). Esse campo representa o valor simbólico para essa propriedade.
- Campo (h): Concentração do dopante tipo P. Pode conter um valor compreendido entre 0,1 a 0,9. Esse campo representa o valor normalizado para essa propriedade que varia de 1 a 9.

- Campo (i): Ordem de grandeza do dopante tipo P. Pode conter os valores 0,000 ( $10^{13}$ ); 0,333 ( $10^{14}$ ); 0,666 ( $10^{15}$ ); 1,000 ( $10^{16}$ ). Esse campo representa o valor simbólico para essa propriedade.

0,732	0,550	0,200	0,500	0,800	0,666	0,000	0,300	1,000	0,250	0,550	0,600	0,270
(a)	(b)	(c)	(d)	(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)	(m)

**Fig. D.1: Representação do cromossomo manipulado pelo AG, de acordo com o posicionamento do seu campo de referência: (a) iluminação, (b) temperatura, (c) área, (d) tipo de dopante N, Concentrações: [(e) dopante N, (f) grandeza], (g) tipo de dopante P, Concentrações: [(h) dopante P, (i) grandeza], (j)  $I_{pmp}$ , (k)  $V_{pmp}$ , (l) Voc, (m)  $I_{sc}$ .**

Uma vez gerados, os indivíduos são ordenados de acordo com o resultado da função *fitness* e seus valores de aptidão são colocados numa matriz que contém a informação se um determinado indivíduo já foi escolhido ou não para participar de um cruzamento, como será apresentado no capítulo 4.

#### 4 - Seleção e cruzamento

As funções de seleção e de cruzamento são de grande importância para o bom desempenho do SHG. Durante o processamento os indivíduos presentes na população são selecionados para participar da função de cruzamento. Dentre as formas de seleção apresentadas no Apendice A, a escolhida para ser implementada neste trabalho foi a de competição por torneio, onde são sorteados três indivíduos para se participar do processo de cruzamento. Os dois indivíduos com maior grau de aptidão são os escolhidos para participar da função de cruzamento, onde o pai 1 será o indivíduo com maior aptidão do torneio. Esse procedimento foi escolhido de forma a evitar a convergência prematura dos genes da população (o que provoca a diminuição da variabilidade genética) que é acarretada pelo método Monte Carlo, assim com permitir que mesmo os indivíduos com baixa aptidão genética possam participar do processo de cruzamento.

Como tanto o método por competição (torneio) como o Monte Carlo não garantem que o indivíduo mais bem adaptado de uma geração seja escolhido para participar de um cruzamento, a utilização da estratégia do elitismo foi implementada, de forma a assegurar a perpetuidade do melhor indivíduo gerado [Sab, 1991]. O processo de elitismo só é executado se o melhor indivíduo não participar de nenhum cruzamento.

O processo de seleção vai determinar então os dois pais que participarão do cruzamento e lhes assegura também a selitividade para a nova geração. Cada indivíduo que é selecionado é marcado como escolhido e seu cromossomo é integralmente copiado para a nova população (próxima geração). Caso um indivíduo já tenha sido sorteado anteriormente para participar de um cruzamento, ou seja, já está marcado como escolhido, este indivíduo não terá novamente seu cromossomo copiado para nova população, mas participará normalmente do processo de cruzamento. Esse procedimento tem como função evitar que a nova população seja preenchida com inúmeras cópias de um mesmo indivíduo que foi sorteado várias vezes para participar de um cruzamento, promovendo a variabilidade genética. O processo de seleção permite a ocorrência do autocruzamento, ou seja, um indivíduo é escolhido unicamente para o processo de cruzamento, mas somente uma cópia dele poderá ser transferida para a nova população.

O processo de cruzamento implementado para a resolução do problema foge um pouco do padrão apresentado no capítulo 3. Isso porque são levados em consideração aspectos práticos e teóricos relacionados com a resolução do problema e formatação dos dados. Assim, ocorreu na implementação da função de cruzamento, um conjunto de procedimentos de forma a garantir que todo cruzamento irá gerar filhos válidos com soluções factíveis para o problema. Como o procedimento adotado para a criação dos indivíduos válidos pela função de criação parte dos valores lidos da leitura do arquivo que contém os dados de operação da célula solar, os campos (genes) nos quais podem ser realizados cruzamentos são: (d), (e), (f), (g), (h) e (i); conforme apresentado na Figura D.2. De forma a privilegiar a diversidade genética da população, três formas de cruzamento são implementadas e sorteadas aleatoriamente. São elas:

- Sorteio de três genes: Três genes são sorteados aleatoriamente e trocados de lugar com os pais, mantendo-se a mesma ordem dos campos. Nesse tipo de cruzamento, o autocruzamento é proibido, de forma a diminuir as chances de criar filhos geneticamente

idênticos aos pais. A Figura D.2 apresenta um exemplo desse tipo de cruzamento no fragmento de um cromossomo.

- Inversão da Concentração 1: Nesse tipo de cruzamento, a concentração de um elemento tipo P de um pai é trocada com a concentração do elemento tipo N do outro pai. Ou seja, num cromossomo os campos (h) e (i) são trocados com os campos (e) e (f) respectivamente para gerar um filho. No outro pai os campos (e) e (f) são trocados com os campos (h) e (i) respectivamente para gerar o outro filho. Essa inversão é permitida pois os campos (e) e (h); (f) e (i) representam o mesmo tipo de informação. Nesse tipo de cruzamento é permitida a ocorrência do autocruzamento. A Figura D.3 apresenta um exemplo desse tipo de cruzamento no fragmento de um cromossomo.
- Inversão da Concentração 2: parecido com a inversão da concentração 1, porém os campos (e) e (f) são trocados com os campos (h) e (i) respectivamente para gerar um filho. No outro pai os campos (h) e (i) são trocados com os campos (e) e (f) respectivamente para gerar o outro filho. Nesse tipo de cruzamento é permitida a ocorrência do autocruzamento. A Figura D.4 apresenta um exemplo desse tipo de cruzamento no fragmento de um cromossomo.

Pai 1						Pai 2					
(d)	(e)	(f)	(g)	(h)	(i)	(d)	(e)	(f)	(g)	(h)	(i)
0,000	0,100	0,666	0,300	0,700	1,000	0,500	0,200	0,000	0,000	0,300	0,333
Filho 1						Filho 2					
0,500	0,100	0,666	0,000	0,700	0,333	0,000	0,200	0,000	0,300	0,300	1,000

**Fig. D.2:** Sorteio de três campos para realizar o cruzamento, neste exemplo os campos sorteados foram (d), (g) e (i).

Pai 1						Pai 2					
(d)	(e)	(f)	(g)	(h)	(i)	(d)	(e)	(f)	(g)	(h)	(i)
0,000	0,100	0,666	0,300	0,700	1,000	0,500	0,200	0,000	0,000	0,300	0,333
Filho 1						Filho 2					
0,000	0,300	0,333	0,300	0,700	1,000	0,500	0,200	0,000	0,000	0,100	0,666

**Fig. D.3:** Inversão de concentração tipo 1. Campos (e) e (f) do pai 1 para os campos (h) e (i) do filho 2 respectivamente, campos (h) e (i) do pai 2 para os campos (e) e (f) do filho 1 respectivamente.

Pai 1						Pai 2					
(d)	(e)	(f)	(g)	(h)	(i)	(d)	(e)	(f)	(g)	(h)	(i)
0,000	0,100	0,666	0,300	0,700	1,000	0,500	0,200	0,000	0,000	0,300	0,333
Filho 1						Filho 2					
0,000	0,100	0,666	0,300	0,200	0,000	0,500	0,700	1,000	0,000	0,300	0,333

**Fig. D.4:** Inversão de concentração tipo 2. Campos (h) e (i) do pai 1 para os campos (e) e (f) do filho 2 respectivamente, campos (e) e (f) do pai 2 para os campos (h) e (i) do filho 1 respectivamente.

Como a função de seleção está implementada pelo procedimento de torneio, e esta sempre realiza o cruzamento entre o mais apto (pai 1) com o segundo mais apto (pai 2) dos participantes do torneio. Assim não há o risco da ocorrência do cruzamento do tipo pai 2 com pai 1, o que diminuiria a variabilidade genética do cruzamento gerando filhos iguais nos dois processos de inversão de concentração.

## 5 - Mutação

O outro operador genético aplicado no SHG é o procedimento de mutação dos genes do cromossomo. O procedimento de mutação somente acontece após a realização de todos os cruzamentos da população antiga. Um indivíduo da população antiga é sorteado e um dos genes presentes nos campos (d), (e), (f), (g), (h), (i), conforme apresentado nas Figuras D.1, D.2 e D.3; também é sorteado para a ocorrência da mutação de acordo com as normas estabelecidas para os dados apresentados no capítulo 4 e implementados na função de criação apresentados no capítulo 4. Assim o processo de mutação somente irá gerar indivíduos válidos. Uma vez realizado o procedimento de mutação o novo indivíduo é então copiado para a nova população. Esse procedimento se repete até que o percentual de mutação estabelecido nos parâmetros de utilização SHG sejam alcançados. A Figura D.5 apresenta a ocorrência do processo de mutação do indivíduo no trecho do cromossomo.

Indivíduo Sorteado					
(d)	(e)	(f)	(g)	(h)	(i)
0,000	0,100	0,666	0,300	0,700	1,000
Indivíduo após a Mutação					
0,000	0,100	1,000	0,300	0,700	1,000

**Fig. D.5: Exemplo da ocorrência do processo de mutação ocorrida no campo (f) do cromossomo.**

## Apêndice E – Tabelas de Execução da RNA de acordo com cada configuração

Tabela E.1: Avaliação do processamento da RNA para o modelo PMCCF

Num. da Experiência	Neurônios na camada escondida	Erro Médio Quadrático após 500 Iterações	Erro Médio Quadrático ao final do processamento	Convergência dos dados	Precisão do Erro para solução do problema
1	5	0.008953	0.00323	Não Convergiu	Insuficiente
2	10	0.004730	0.00197	Não Convergiu	Insuficiente
3	25	0.003689	0.00101	Não Convergiu	Insuficiente
4	50	0.003186	0.00082	Convergiu	Insuficiente
5	75	0.003206	0.00049	Convergiu	Insuficiente
6	100	0.003017	0.00010	Convergiu	Insuficiente
7	150	0.002930	0.00007	Convergiu	Suficiente
8	200	0.002809	0.00005	Convergiu	Suficiente
9	250	0.002723	0.00003	Convergiu	Suficiente
10	300	0.002858	0.00001	Convergiu	Suficiente
11	350	0.003926	0.00006	Convergiu	Suficiente
12	400	0.004514	0.00012	Convergiu	Insuficiente
13	450	0.024959	0.00097	Não Convergiu	Insuficiente
14	500	0.053110	0.00231	Não Convergiu	Insuficiente

Tabela E.2: Estrutura da RNA para o modelo PMCCF

Característica	Valor
Entradas	9
Saídas	4 – (Vmax, Imax, Voc, Isc).
Número de camadas escondidas	1 – camada escondida .
Neurônios na camada escondida	300 – Neurônios.
Função de ativação dos neurônios	Sigmóide binária.
Algoritmo de aprendizagem	Backpropagation.
Taxa de aprendizagem	Variante entre 0,4 a 0,001 (40% a 0,1%) com ajuste automática.
Momento	Variante entre 0,39 a 0 (sempre menor que a taxa de aprendizagem).
Estratégia de Aprendizado.	Supervisionado com ajuste automática da taxa de aprendizagem.
Número de iterações	41404

Tabela E.3: Formatação dos dados da RNA para o modelo PMCCF

Característica	Tipo de representação	Tipo de normalização	Faixa de Valores	Unidade
Irradiância	Representativo	(valor)/1367	0 a 1367	w.m <sup>-2</sup>
Temperatura	Representativo	(valor+100)/200	-100 a 100	°C
Área	Representativo	(valor)/500	50 a 500	Cm <sup>2</sup>
Elemento dopante tipo N	Simbólico	-----	0,000 (As) 0,500 (Sb) 1,000 (P)	-----
Concentração do elemento N	Representativo	(valor)/10	1 a 9	Átomos.cm <sup>-3</sup>
Grandeza de concentração	Simbólico	-----	0,000 (10 <sup>13</sup> ) 0,333 (10 <sup>14</sup> ) 0,666 (10 <sup>15</sup> ) 1,000 (10 <sup>16</sup> )	-----
Elemento dopante tipo P	Simbólico	-----	0,000 (B) 0,300 (Al) 0,600 (Ga) 1,000 (In)	-----
Concentração do elemento P	Representativo	(valor)/10	1 a 9	Átomos.cm <sup>-3</sup>
Grandeza de concentração	Simbólico	-----	0,000 (10 <sup>13</sup> ) 0,333 (10 <sup>14</sup> ) 0,666 (10 <sup>15</sup> ) 1,000 (10 <sup>16</sup> )	-----
Tensão no ponto de máximo	Representativo	-----	0 a 1	Volts
Corrente no ponto de máximo	Representativo	(valor)/10	0 a 10	Ampères
Tensão em circuito aberto	Representativo	-----	0 a 1	Volts
Corrente de curto circuito	Representativo	(valor)/10	0 a 10	Ampères

Tabela E.4: Avaliação do processamento da RNA para o modelo PC-1D

Num. da Experiência	Neurônios na camada escondida	Erro Médio Quadrático após 500 Iterações	Erro Médio Quadrático ao final do processamento	Convergência dos dados	Precisão do Erro para solução do problema
1	5	$6,27 \times 10^{-1}$	$1,33 \times 10^{-1}$	Não Convergiu	Insuficiente
2	10	$4,84 \times 10^{-1}$	$5,51 \times 10^{-2}$	Não Convergiu	Insuficiente
3	25	$4,50 \times 10^{-1}$	$3,23 \times 10^{-2}$	Não Convergiu	Insuficiente
4	50	$4,25 \times 10^{-1}$	$3,01 \times 10^{-2}$	Convergiu	Insuficiente
5	75	$4,02 \times 10^{-1}$	$2,85 \times 10^{-2}$	Convergiu	Suficiente
6	100	$3,95 \times 10^{-1}$	$2,85 \times 10^{-2}$	Convergiu	Suficiente
7	150	$3,81 \times 10^{-1}$	$3,06 \times 10^{-2}$	Convergiu	Insuficiente
8	200	$3,83 \times 10^{-1}$	$3,26 \times 10^{-2}$	Não Convergiu	Insuficiente
9	250	$3,84 \times 10^{-1}$	$2,73 \times 10^{-2}$	Não Convergiu	Insuficiente
10	300	$4,00 \times 10^{-1}$	$2,88 \times 10^{-2}$	Não Convergiu	Insuficiente

Tabela E.5: Estrutura da RNA para o modelo PC-1D

Característica	Valor
Entradas	21
Saídas	Entre 21 e 320 dependendo da rede
Número de camadas escondidas	1 – camada escondida .
Neurônios na camada escondida	Entre 50 e 75
Função de ativação dos neurônios	Sigmóide tangente hiperbólica
Algoritmo de aprendizagem	Backpropagation.
Taxa de aprendizagem	Variante entre 0,4 a 0,001 (40% a 0,1%) com ajuste automática.
Momento	Variante entre 0,39 a 0 (sempre menor que a taxa de aprendizagem).
Estratégia de Aprendizado.	Supervisionado com ajuste automática da taxa de aprendizagem.
Número de iterações	50000 (Max)
Número de RNAs Utilizadas	6 no total, sendo: Propriedades físicas: 1 Densidade de Corrente: 3 Densidade de Portadores: 2

## Apêndice F – Equacionamento do modelo matemático determinístico do modelo PMCCF.

---

**Equação F.1.**

$$f = \frac{c}{\lambda}$$

Onde:

$f$ : Frequência da onda incidente (Hz).

$\lambda$ : Comprimento de onda (nm).

$c$ : Velocidade da luz ( $\text{m.s}^{-1}$ ).

---

**Equação F.2.**

$$E = \frac{h.c}{\lambda}$$

Onde:

$E$ : Energia do fóton incidente (J).

$h$ : Constante de Plank.

$\lambda$ : Comprimento da onda incidente (nm).

---

**Equação F.3.**

$$\alpha = \frac{4.\pi.k}{\lambda}$$

Onde:

$\alpha$ : Constante de absorção.

$k$ : Coeficiente de Extinção.

$\lambda$ : Comprimento de onda (nm).



---

**Equação F.4.**

$$IL = IL_0 \cdot e^{-\alpha \cdot x}$$

Onde:

$IL$ : Intensidade luminosa restante após certa profundidade ( $\text{W} \cdot \text{m}^{-1}$ ).

$IL_0$ : Intensidade luminosa incidente ( $\text{W} \cdot \text{m}^{-1}$ ).

$\alpha$ : Constante de absorção.

$x$ : Profundidade de penetração no semiconductor (m).

---

**Equação F.5.**

$$L_n = \sqrt{D_n \cdot \tau_n}$$

Onde:

$L_n$ : Comprimento percorrido pelo portador minoritário no semiconductor tipo P (m).

$D_n$ : Constante de Difusão dos elétrons.

$\tau_n$ : Tempo de vida dos portadores minoritários (s).

---

**Equação F.6.**

$$L_p = \sqrt{D_p \cdot \tau_p}$$

Onde:

$L_p$ : Comprimento percorrido pelo portador minoritário no semiconductor tipo N (m).

$D_p$ : Constante de Difusão das lacunas.

$\tau_p$ : Tempo de vida dos portadores minoritários (s).

---

**Equação F.7.**

$$n \approx N_d$$

Onde:

$n$ : Concentração de elétrons no semiconductor tipo N ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$N_d$ : Concentração de impurezas doadoras adicionadas no semiconductor ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

---

**Equação F.8.**

$$p \approx \frac{n_i^2}{N_d}$$

Onde:

$p$ : Concentração de lacunas no semicondutor tipo N (átomos.cm<sup>-3</sup>).

$n_i$ : Concentração intrínseca do semicondutor (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras adicionadas no semicondutor (átomos.cm<sup>-3</sup>).

---

**Equação F.9.**

$$p \approx N_a$$

Onde:

$p$ : Concentração de lacunas no semicondutor tipo p (átomos.cm<sup>-3</sup>).

$N_a$ : Concentração de impurezas aceitadoras adicionadas no semicondutor (átomos.cm<sup>-3</sup>).

---

**Equação F.10.**

$$n \approx \frac{n_i^2}{N_a}$$

Onde:

$n_i$ : Concentração intrínseca do semicondutor (átomos.cm<sup>-3</sup>).

$n$ : Concentração de elétrons no semicondutor tipo P (átomos.cm<sup>-3</sup>).

$N_a$ : Concentração de impurezas aceitadoras adicionadas no semicondutor (átomos.cm<sup>-3</sup>).

---

**Equação F.11.**

$$V_{bi} = \left( \frac{k.T}{q} \right) \cdot \ln \left( \frac{N_a \cdot N_d}{n_i^2} \right)$$

Onde:

$V_{bi}$ : Barreira potencial da junção pn (V).

$k$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$q$ : Carga do elétron (eV).

$N_a$ : Concentração de impurezas aceitadoras no semiconductor P (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras no semiconductor N (átomos.cm<sup>-3</sup>).

$n_i$ : Concentração intrínseca do material semiconductor (átomos.cm<sup>-3</sup>).

---

**Equação F.12.**

$$W_n = \left[ \frac{2 \cdot \epsilon \cdot N_a}{q \cdot N_a \cdot (N_a + N_d)} \right]^{1/2} \cdot (v_{bi} - v)^{1/2}$$

Onde:

$W_n$ : Comprimento da camada de depleção sobre o semiconductor tipo N (nm).

$\epsilon$ : Permissividade do material.

$q$ : Carga do elétron (eV).

$N_a$ : Concentração de impurezas aceitadoras (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras (átomos.cm<sup>-3</sup>).

$v_{bi}$ : Barreira potencial (V).

$v$ : Tensão da carga aplicada (V).

**Equação F.13.**

$$W_p = \left[ \frac{2 \cdot \epsilon \cdot N_d}{q \cdot N_a \cdot (N_a + N_d)} \right]^{1/2} \cdot (v_{bi} - v)^{1/2}$$

Onde:

$W_p$ : Comprimento da camada de depleção sobre o semiconductor tipo N (nm).

$\epsilon$ : Permissividade do material.

$q$ : Carga do elétron (eV).

$N_a$ : Concentração de impurezas aceitadoras (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras (átomos.cm<sup>-3</sup>).

$v_{bi}$ : Barreira potencial (V).

$v$ : Tensão da carga aplicada (V).

**Equação F.14.**

$$I_0 = q \cdot A \cdot n_i^2 \cdot \left( \frac{1}{N_a} \cdot \sqrt{\frac{D_n}{\tau_n}} \cdot \coth\left(\frac{W_p}{L_n}\right) + \frac{1}{N_d} \cdot \sqrt{\frac{D_p}{\tau_p}} \cdot \coth\left(\frac{W_n}{L_p}\right) \right)$$

Onde:

$I_0$ : Corrente reversa de Saturação (A).

$q$ : Carga do elétron (C).

$A$ : Área (m<sup>2</sup>)

$n_i^2$ : Concentração intrínseca (átomos.cm<sup>-3</sup>).

$N_a$ : Concentração de impurezas aceitadoras (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras (átomos.cm<sup>-3</sup>).

$D_n$ : Constante de difusão de elétrons.

$D_p$ : Constante de difusão das lacunas.

$\tau_n$ : Tempo de vida dos portadores minoritários elétrons (s).

$\tau_p$ : Tempo de vida dos portadores minoritários lacunas (s).

$W_p$ : Comprimento da camada de depleção do lado P (nm).

$W_n$ : Comprimento da camada de depleção do lado N (nm).

$L_n$ : Comprimento percorrido pelo portador minoritário do lado N (nm).

$L_p$ : Comprimento percorrido pelo portador minoritário do lado P (nm).

---

**Equação F.15.**

$$E_c = \left(\frac{3}{2}\right)k.T$$

Onde:

$E_c$ : Energia Cinética (J).

$k$ : Constante de Boltzmann.

$T$ : Temperatura (K).

---

**Equação F.16.**

$$V_{tn} = \sqrt{\left(\frac{2.E_c}{m_{ee}}\right)}$$

Onde:

$V_{tn}$ : Velocidade térmica no semicondutor N ( $\text{cm.s}^{-1}$ ).

$E_c$ : Energia cinética (J).

$m_{ee}$ : Massa efetiva dos elétrons (g).

---

**Equação F.17.**

$$V_{tp} = \sqrt{\left(\frac{2.E_c}{m_{el}}\right)}$$

Onde:

$V_{tp}$ : Velocidade térmica no semicondutor tipo P ( $\text{cm.s}^{-1}$ ).

$E_c$ : Energia cinética (J).

$m_{el}$ : Massa efetiva das lacunas (g).

---

**Equação F.18.**

$$a_{cn} = A - (\pi \cdot L_n)$$

Onde:

$a_{cn}$ : Área de captura do elétron (m<sup>2</sup>).

$A$ : Área de secção transversal (m<sup>2</sup>).

$L_n$ : Comprimento percorrido pelo portador minoritário do lado N (nm).

---

**Equação F.19.**

$$a_{cp} = A - (\pi \cdot L_p)$$

Onde:

$a_{cp}$ : Área de captura da lacuna (m<sup>2</sup>).

$A$ : Área de secção transversal (m<sup>2</sup>).

$L_p$ : Comprimento percorrido pelo portador minoritário do lado P (nm).

---

**Equação F.20.**

$$S_n = a_{cn} \cdot V_m \cdot DEE_{cc}$$

Onde:

$S_n$ : Velocidade de recombinação superficial do lado N (cm.s<sup>-1</sup>).

$a_{cn}$ : Área de captura do elétron (m<sup>2</sup>).

$V_{tn}$ : Velocidade térmica no semiconductor tipo N (cm.s<sup>-1</sup>).

$DEE_{cc}$ : Densidade efetiva de estados na camada de condução.

---

**Equação F.21.**

$$S_p = a_{cp} \cdot V_{tp} \cdot DEE_{cv}$$

Onde:

$S_p$ : Velocidade de recombinação superficial no lado P (cm.s<sup>-1</sup>).

$a_{cp}$ : Área de captura da lacuna (m<sup>2</sup>).

$V_{tp}$ : Velocidade térmica no semiconductor tipo P (cm.s<sup>-1</sup>).

$DEE_{cv}$ : Densidade efetiva de estados na camada de valência.

---

**Equação F.22.**

$$I_{ln} = \frac{q \cdot A \cdot F_{ph} \cdot \alpha \cdot L_n}{\alpha^2 \cdot L_n^2 - 1} \cdot \left[ \frac{S_n \cdot \cosh\left(\frac{W_p}{L_n}\right) + \frac{D_n}{L_n} \cdot \sinh\left(\frac{W_p}{L_n}\right) + (\alpha \cdot D_n - S_n) \cdot e^{-\alpha \cdot W_p}}{S_n \cdot \sinh\left(\frac{W_p}{L_n}\right) + \frac{D_n}{L_n} \cdot \cosh\left(\frac{W_p}{L_n}\right)} \right] - \alpha \cdot L_n$$

Onde:

$I_{ln}$ : Fotocorrente gerada no semiconductor tipo N (A).

$q$ : Carga do elétron (C).

$A$ : Área da secção transversal (m<sup>2</sup>).

$F_{ph}$ : Número de fótons próximos a camada de depleção para cada comprimento de onda.

$\alpha$ : Constante de absorção.

$L_n$ : Comprimento percorrido pelo portador minoritário do lado N (nm).

$S_n$ : Velocidade de recombinação superficial no lado N (cm.s<sup>-1</sup>).

$W_p$ : Comprimento da camada de depleção do lado P (nm).

$D_n$ : Coeficiente de difusão dos elétrons.

---

**Equação F.23.**

$$I_{lp} = \frac{q \cdot A \cdot F_{ph} \cdot \alpha \cdot L_p}{\alpha^2 \cdot L_p^2 - 1} \cdot \left[ \frac{S_p \cdot \cosh\left(\frac{W_n}{L_p}\right) + \frac{D_p}{L_p} \cdot \sinh\left(\frac{W_n}{L_p}\right) + (\alpha \cdot L_p - S_p) \cdot e^{-\alpha \cdot W_n}}{S_p \cdot \sinh\left(\frac{W_n}{L_p}\right) + \frac{D_p}{L_p} \cdot \cosh\left(\frac{W_n}{L_p}\right)} \right] - \alpha \cdot L_p$$

Onde:

$I_{lp}$ : Fotocorrente gerada no semicondutor tipo P (A).

$q$ : Carga do elétron (C).

$A$ : Área da secção transversal ( $m^2$ ).

$F_{ph}$ : Número de fótons próximos a camada de depleção para cada comprimento de onda.

$\alpha$ : Constante de absorção.

$L_p$ : Comprimento percorrido pelo portador minoritário do lado P (nm).

$S_p$ : Velocidade de recombinação superficial no lado P ( $cm \cdot s^{-1}$ ).

$W_n$ : Comprimento da camada de depleção do lado N (nm).

$D_p$ : Coeficiente de difusão das lacunas.

---

**Equação F.24.**

$$I_l = I_{ln} + I_{lp}$$

Onde:

$I_l$ : Fotocorrente total gerada (A).

$I_{ln}$ : Fotocorrente gerada no semicondutor tipo N (A).

$I_{lp}$ : Fotocorrente gerada no semicondutor tipo P (A).



---

**Equação F.25.**

$$V_{oc} = \left( \frac{k.T}{q} \right) \cdot \ln \left( \frac{I_l}{I_0} \right)$$

Onde:

$V_{oc}$ : Tensão em circuito aberto (V).

$k$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$q$ : Carga do elétron (C).

$I_l$ : Fotocorrente total gerada (A).

$I_0$ : Corrente reversa de saturação (A).

---

**Equação F.26.**

$$I_{sc} = I_l - I_0 \cdot \left( e^{\frac{q.V_{oc}}{k.T}} - 1 \right)$$

Onde:

$I_{sc}$ : Corrente de curto circuito (A).

$I_l$ : Fotocorrente total gerada (A).

$I_0$ : Corrente reversa de saturação (A).

$q$ : Carga do elétron (C).

$V_{oc}$ : Tensão em circuito aberto (V).

$k$ : Constante de Boltzmann.

$T$ : Temperatura (K).

# Anexos

## Anexo 1 – Equacionamento do modelo matemático do PC-1D.

O PC-1D é um software para computador pessoal que usa a análise de elementos finitos para solucionar um conjunto de equações de transporte dos portadores do semicondutor em uma dimensão. Ele é utilizado para a análise de desempenho de dispositivos óptico eletrônicos como células solares (fonte).

As equações do semicondutor são não lineares e requerem uma solução iterativa. A solução tem a convergência quando a máxima mudança de qualquer valor eletrostático ou de potencial quase-fermi, normalizado pela voltagem termal ( $kT/q$ ), cai abaixo do nível de erro estabelecido. Por padrão esse erro limite é de  $1 \times 10^{-6}$ .

A seguir são apresentadas as Equações Utilizadas no processamento do software PC-1D

Equação 1 mobilidade de elétrons e lacunas. O modelo de mobilidade é função da concentração de dopagem total em cada posição do semicondutor e da temperatura do dispositivo.

### Equação 1.

$$\mu = \mu_{min} \cdot T_n^{\beta_1} + \frac{(\mu_{max} - \mu_{min}) \cdot T_n^{\beta_2}}{1 + \left\{ \frac{N_d + N_a}{N_{ref} \cdot T_n^{\beta_3}} \right\}^{\alpha \cdot T_n^{\beta_4}}}$$

Onde:

$\mu$ : Mobilidade de elétrons ou lacunas ( $\text{cm}^2 \cdot \text{V}_s^{-1}$ ).

$\mu_{min}$ : Mobilidade mínima de elétrons ou lacunas ( $\text{cm}^2 \cdot \text{V}_s^{-1}$ ).

$\mu_{max}$ : Mobilidade máxima de elétrons ou lacunas ( $\text{cm}^2 \cdot \text{V}_s^{-1}$ ).

$N_a$ : Concentração de impurezas aceitadoras (átomos. $\text{cm}^{-3}$ ).

$N_d$ : Concentração de impurezas doadoras (átomos. $\text{cm}^{-3}$ ).

$N_{ref}$ : Concentração intrínseca de referência (átomos. $\text{cm}^{-3}$ ).

$T_n = T/300K$  Temperatura normalizada (K).

$\alpha$ : Constante de proporcionalidade.

$\beta_1, \beta_2, \beta_3, \beta_4$ : Coeficientes de temperatura (K).

### Equação 2.

$$\mu_{HF} = \mu_{LF} / \sqrt{1 + (\mu_{LF} \cdot E / V_{sat})^2}$$

Onde:

$\mu_{HF}$ : Valor da mobilidade de campo elétrico alto ( $\text{cm}^2 \cdot \text{V}_s^{-1}$ ).

$\mu_{LF}$ : Valor da mobilidade de campo elétrico baixo ( $\text{cm}^2 \cdot \text{V}_s^{-1}$ ).

$V_{sat}$ : Velocidade de saturação ( $\text{cm} \cdot \text{s}^{-1}$ ).

O modelo interno para a absorção de fóton incluem duas transições de gaps diretos e oito transições indiretas. As transições indiretas são baseados em dois gaps indiretos e outros absorções para a criação de fótons e tem duas possibilidades e energia. O efeito da temperatura afeta o coeficiente de absorção  $\alpha$ , através do decréscimo in bandas de energia gap e através da mudança da probabilidade de transições apoiadas por fônons. Todas as 4 gaps de energia são assumidas para dependência da temperatura absoluta, através do coeficiente de temperatura e da temperatura offset.

**Equação 3.**

$$E_G = E_{G0} - \frac{\beta T^2}{T + \gamma}$$

Onde:

$E_G$ : Energia GAP (eV).

$E_{G0}$ : Energia GAP inicial (eV).

$\beta$ : Coeficiente de temperatura (K).

$T$ : Temperatura (K).

$\gamma$ : Temperatura off set (K).

A contribuição para o coeficiente de absorção para as duas transições diretas para os fótons com energia  $h_\nu$  é maior que a energia GAP  $E_{Gdi}$  são dados por:

**Equação 4.**

$$\alpha_{di} = A_{di} \sqrt{h_\nu - E_{Gdi}} \text{ para } i = 1, 2$$

Onde:

$\alpha_{di}$ : Coeficiente de absorção direta.

$A_{di}$ : Área de secção Transversal direta (cm<sup>2</sup>)

$h_\nu$ : Energia do fóton (eV).

$E_{Gdi}$ : Energia GAP direta (eV).

As oito transições auxiliadas por fônons para GAP indireto  $E_{Gi}$  e a energia do phonon  $E_{pj}$  tem a forma de:

**Equação 5.**

$$\alpha_{ij}(\pm) = A_{ij} \cdot \frac{(h_\nu - E_{Gi} \pm E_{pj})^2}{\pm \left( e^{\pm E_{pj}/KT} - 1 \right)}, i = 1, 2; j = 1, 2$$

Onde:

$\alpha_{ij}$ : Coeficiente de absorção para transições auxiliadas por fônons.

$A_{ij}$ : Área de seção transversal para transições auxiliadas por fônons.

$E_{Gi}$ : Energia Gap Indireta (eV).

$E_{pj}$ : Energia do fônon (eV).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

O sinal de mais é correspondente as transições de absorção do phonon, enquanto o sinal de menos é correspondente as transições de criação do phonon. Somente esses termos para qual  $h_\nu \pm E_{pj} > E_{Gi}$  são incluídos. Onde

**Equação 6.**

$$h_\nu = h \cdot c / \lambda, \text{ e } h \cdot c = 1238,8424 \text{ eV} \cdot \text{nm}$$

Onde:

$h_\nu$ : Energia do fóton (eV).

$h$ : Constante de Planck.

$c$ : Velocidade da luz no vácuo (m.s<sup>-1</sup>).

$\lambda$ : Comprimento de onda (nm).

**Equação 7.**

$$n_{eq} \cdot p_{eq} = n_i^2(T) e^{(\Delta E_c + \Delta E_v)/kT}$$

Onde:

$n_{eq}$ : Concentração de elétrons no equilíbrio térmico (átomos.cm<sup>-3</sup>).

$p_{eq}$ : Concentração de lacunas no equilíbrio térmico (átomos.cm<sup>-3</sup>).

$n_i^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

$\Delta E_c$ : Fronteira da banda de condução (eV).

$\Delta E_v$ : Fronteira da banda de valência (eV).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

**Equação 8.**

$$\Delta E_c = C_d \cdot \ln(N_d/N_{d0}); N_d > N_{d0}$$

Onde:

$\Delta E_c$ : Fronteira da banda de condução (eV).

$C_d$ : Dopagem de partículas doadoras (átomos.cm<sup>-3</sup>).

$N_d$ : Concentração de impurezas doadoras (átomos.cm<sup>-3</sup>).

$N_{d0}$ : Concentração de impurezas doadoras inicial (átomos.cm<sup>-3</sup>).

**Equação 9.**

$$\Delta E_v = C_a \cdot \ln(N_a/N_{a0}); N_a > N_{a0}$$

Onde:

$\Delta E_v$ : Fronteira da banda de valência (eV).

$C_a$ : Dopagem de partículas aceitadoras (átomos.cm<sup>-3</sup>).

$N_a$ : Concentração de impurezas aceitadoras (átomos.cm<sup>-3</sup>).

$N_{a0}$ : Concentração de impurezas doadoras inicial (átomos.cm<sup>-3</sup>).

O PC-1D irá modificar este valor utilizando a bandagap intrínseca específica para obter o valor da concentração intrínseca dos portadores que são especificados pela temperatura, usando

**Equação 10.**

$$n_i(T) = n_i(T_0) \cdot \left(T/T_0\right)^{3/2} \cdot e^{(E_g/2kT_0 - E_g/2kT)}, \text{ onde } kT_0 = 25,851483 \text{ meV}$$

Onde:

$n_i(T)$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

$n_i(T_0)$ : Concentração Intrínseca Inicial (átomos.cm<sup>-3</sup>).

$T$ : Temperatura (K).

$T_0$ : Temperatura Inicial (K).

$E_g$ : Energia GAP (eV).

$K$ : Constante de Boltzmann.

A taxa de recombinação *Auger* é a soma de dois termos:

**Equação 11.**

$$R = (C_{nh} \cdot N_d + C_{ph} \cdot N_a) \cdot (pn - n_{ie}^2)$$

Onde:

$R$ : Taxa de Recombinação (cm<sup>3</sup>.s<sup>-1</sup>).

$C_{nh}$ : Região de forte dopagem do lado N.

$N_d$ : Concentração de impurezas doadoras (átomos.cm<sup>-3</sup>).

$C_{ph}$ : Região de forte dopagem do lado P.

$N_a$ : Concentração de impurezas aceitadoras (átomos.cm<sup>-3</sup>).

$pn$ : Concentração de elétrons x concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

#### Equação 12.

$$R = [C_{nl}(n - n_{eq}) + C_{pl}(p - p_{eq})](pn - n_{ie}^2)$$

Onde:

$R$ : Taxa de Recombinação (cm<sup>3</sup>.s<sup>-1</sup>).

$C_{nl}$ : Região de leve dopagem do lado N.

$n$ : Concentração de elétrons (átomos.cm<sup>-3</sup>).

$n_{eq}$ : Concentração de elétrons no equilíbrio térmico (átomos.cm<sup>-3</sup>).

$C_{pl}$ : Região de leve dopagem do lado P.

$p$ : Concentração de lacunas (átomos.cm<sup>-3</sup>).

$p_{eq}$ : Concentração de lacunas no equilíbrio térmico (átomos.cm<sup>-3</sup>).

$pn$ : Concentração de elétrons x concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

O primeiro termo domina regiões fortemente dopadas, enquanto o segundo termo é importante em regiões levemente dopadas. A recombinação banda-para-banda é também incluída e tem a forma

#### Equação 13.

$$R = B(pn - n_{ie}^2)$$

Onde:

$R$ : Taxa de Recombinação (cm<sup>3</sup>.s<sup>-1</sup>).

$B$ : Coeficiente do material semiconductor.

$pn$ : Concentração de elétrons x concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

#### Equação 14.

Uniforme:  $N(x) = N_s$ , para  $x < x_d$ .

Onde:

$N_{(x)}$ : Difusão de dopantes de acordo com a profundidade.

$N_s$ : Pico de concentração (átomos.cm<sup>-3</sup>).

#### Equação 15.

$$\text{Exponencial: } N(x) = N_s \cdot \exp \left[ -|x - x_p| / x_d \right]$$

Onde:

$N_{(x)}$ : Difusão de dopantes de acordo com a profundidade.

$N_s$ : Pico de concentração (átomos.cm<sup>-3</sup>).

$x$ : Profundidade (m).

$x_p$ : Profundidade do pico (m).

$x_d$ : Fator do perfil de profundidade.

#### Equação 16.

$$\text{Gaussiana: } N(x) = N_s \cdot \exp \left[ -\frac{(x - x_p)^2}{x_d^2} \right]$$

Onde:

$N_{(x)}$ : Difusão de dopantes de acordo com a profundidade.

$N_s$ : Pico de concentração (átomos.cm<sup>-3</sup>).

$x$ : Profundidade (m).

$x_p$ : Profundidade do pico (m).

$x_d$ : Fator do perfil de profundidade.

**Equação 17.**

$$\text{ErFc: } N(x) = N_s \cdot \text{erfc}[x/x_d]$$

Onde:

$N_{(x)}$ : Difusão de dopantes de acordo com a profundidade.

$N_s$ : Pico de concentração (átomos.cm<sup>-3</sup>).

$x$ : Profundidade (m).

$x_d$ : Fator do perfil de profundidade.

Onde:  $N_s$  é o pico de concentração,  $x_p$  é a profundidade do pico,  $x_d$  é o fator de perfil e  $x$  é a distância da região especificada até a superfície.

O modelo de recombinação bulk usa a equação SRH Shockley-Read-Hall com separação do tempo de vida para elétrons e lacunas e um ajuste do nível de energia da banda GAP.

**Equação 18.**

$$R = \frac{pn - n_{ie}^2}{\tau_{n0} \left( p + n_{ie} \cdot e^{-E_t/KT} \right) + \tau_{p0} \left( n + n_{ie} \cdot e^{E_t/KT} \right)}$$

Onde:

$R$ : Taxa de Recombinação (cm<sup>3</sup>.s<sup>-1</sup>).

$pn$ : Concentração de elétrons x concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

$\tau_{n0}$ : Tempo de vida dos portadores minoritários [elétrons] (s).

$p$ : Concentração de lacunas (átomos.cm<sup>-3</sup>).

$E_t$ : Nível da armadilha.

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$\tau_{p0}$ : Tempo de vida dos portadores minoritários [lacunas] (s).

$n$ : Concentração de elétrons (átomos.cm<sup>-3</sup>).

O modelo da velocidade de recombinação superficial é baseado na Equação SRH e sua operação é simular ao modelo do tempo de vida *Bulk*.

**Equação 19.**

$$R_s = \frac{pn - n_{ie}^2}{\left( p + n_{ie} \cdot e^{-E_{ts}/KT} \right) / S_n + \left( n + n_{ie} \cdot e^{E_{ts}/KT} \right) / S_p}$$

Onde:

$R_s$ : Recombinação superficial (cm<sup>3</sup>.s<sup>-1</sup>).

$pn$ : Concentração de elétrons x concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}^2$ : Concentração Intrínseca (átomos.cm<sup>-3</sup>).

$p$ : Concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ie}$ : Concentração Intrínseca (átomo.cm<sup>-3</sup>).

$E_{ts}$ : Nível da armadilha na superfície.

$S_n$ : Velocidade de recombinação do lado N (cm.s<sup>-1</sup>)

$S_p$ : Velocidade de recombinação superficial do lado P (cm.s<sup>-1</sup>)

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

O modelo de densidade de corrente de saturação causa a recombinação na superfície para ser diretamente relacionado ao excesso do produto  $pn$  na superfície, na qual a volta é relacionada ao *splitting* do potencial quase-Fermi dos eletrons e lacunas.

**Equação 20.**

$$q \cdot R_s = J_0 (pn - n_{ie}^2)^{1/\gamma} = J_0 \left[ e^{q(\phi_p - \phi_n)/\gamma KT} - 1 \right]$$

Onde:

$q$ : Carga do elétron (C).

$R_s$ : Recombinação superficial ( $\text{cm}^3 \cdot \text{s}^{-1}$ ).

$J_0$ : Densidade de corrente na superfície ( $\text{A} \cdot \text{cm}^{-3}$ ).

$pn$ : Concentração de elétrons x concentração de lacunas ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$n_{ie}^2$ : Concentração Intrínseca ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$\gamma$ : Fator de Idealidade

$\phi_p$ : Potencial quase Fermi para as lacunas.

$\phi_n$ : Potencial quase Fermi para os elétrons.

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

Densidade de corrente

---

**Equação 21.**

$$\bar{J}_n = \mu_n \cdot n \cdot \nabla E_{Fn}$$

Onde:

$\bar{J}_n$ : Densidade de corrente dos elétrons ( $\text{A} \cdot \text{cm}^{-2}$ ).

$\mu_n$ : Mobilidade dos elétrons ( $\text{cm}^2 \cdot \text{Vs}^{-1}$ ).

$n$ : Concentração de elétrons ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$\nabla E_{Fn}$ : Energia quase Fermi do elétron (eV).

---

**Equação 22.**

$$\bar{J}_p = \mu_p \cdot p \cdot \nabla E_{Fp}$$

Onde:

$\bar{J}_p$ : Densidade de corrente das lacunas ( $\text{A} \cdot \text{cm}^{-2}$ ).

$\mu_p$ : Mobilidade das lacunas ( $\text{cm}^2 \cdot \text{Vs}^{-1}$ ).

$p$ : Concentração de lacunas ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$\nabla E_{Fp}$ : Energia Quase Fermi da Lacuna (eV).

---

Para materiais não degenerados, a Boltzmann aproxima a função de distribuição Fermi.

---

**Equação 23.**

$$n = N_c \cdot e^{-(E_c - E_{Fn})/KT}$$

Onde:

$n$ : Concentração de elétrons ( $\text{átomos} \cdot \text{cm}^{-3}$ ).

$N_c$ : Densidade efetiva de estados na camada de condução.

$E_c$ : Fronteira da camada de condução (eV).

$E_{Fn}$ : Energia quase Fermi do elétron (eV).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

---



**Equação 24.**

$$p = N_v \cdot e^{-\frac{(E_{Fp} - E_v)}{KT}}$$

Onde:

$p$ : Concentração de lacunas (átomos.cm<sup>-3</sup>).

$N_v$ : Densidade efetiva de estados na camada de valência.

$E_{Fp}$ : Energia quase Fermi da lacuna (eV).

$E_v$ : Fronteira da camada de valência (eV).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

Para descrever variações na estrutura de banda, dois potenciais da fronteira de banda são introduzidos. Esses potenciais representam o deslocamento (através do centro da banda de separação) da fronteira da banda de condução e de valência com as respectivas condições das referidas localizações, após *accounting* para efeitos eletrostáticos.

**Equação 25.**

$$V_n = \left(\frac{KT}{q}\right) \cdot \ln\left(\frac{N_c}{N_{cr}}\right) + \frac{(x - x_r)}{q} + \nabla E_{Gc}$$

Onde:

$V_n$ : Potencial da banda de fronteira para os elétrons (V).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$q$ : Carga do Elétron (C).

$N_c$ : Densidade de estados na camada de condução.

$N_{cr}$ : Densidade de estados na camada de condução referencial.

$\chi$ : Afinidade do elétron.

$\chi_r$ : Afinidade referencial do elétron.

$\nabla E_{Gc}$ : bandagap narrowing

**Equação 26.**

$$V_p = \left(\frac{KT}{q}\right) \cdot \ln\left(\frac{N_v}{N_{vr}}\right) + \frac{(E_G - E_{Gr})}{q} - \frac{(x - x_r)}{q} + \nabla E_{Gv}$$

Onde:

$V_p$ : Potencial da banda de fronteira para as lacunas (V).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$q$ : Carga do Elétron (C).

$N_v$ : Densidade de estados para a camada de valência.

$N_{vr}$ : Densidade de estados para a camada de valência referencial.

$E_G$ : Energia Gap (eV).

$E_{Gr}$ : Energia Gap referencial (eV).

$\chi$ : Afinidade do elétron.

$\chi_r$ : Afinidade referencial do elétron.

$\nabla E_{Gv}$ : bandagap narrowing

Sendo zero o potencial eletrostático para as condições intrínsecas do material neutro, um novo par de expressões de Boltzmann para  $n$  e  $p$  são definidas.

**Equação 27.**

$$n = n_{ir} \cdot e^{q(\psi + V_n - \phi_n)/KT}$$

Onde:

$n$ : Concentração de elétrons (átomos.cm<sup>-3</sup>).

$n_{ir}$ : Concentração intrínseca referencial (átomos.cm<sup>-3</sup>).

$\psi$ : Potencial (V).

$V_n$ : Potencial da banda de fronteira para os elétrons (V).

$\phi_n$ : Potencial quase Fermi para os elétrons.

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

**Equação 28.**

$$p = n_{ir} \cdot e^{q(-\psi + V_p + \phi_p)/KT}$$

Onde:

$p$ : Concentração de lacunas (átomos.cm<sup>-3</sup>).

$n_{ir}$ : Concentração intrínseca referencial (átomos.cm<sup>-3</sup>).

$\psi$ : Potencial (V).

$V_p$ : Potencial da banda de fronteira para as lacunas (V).

$\phi_p$ : Potencial quase Fermi para as lacunas.

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

Duas equações adicionais podem ser geradas por *accounting* pelo fato de todos os elétrons e lacunas que estão dentro de um certo volume no espaço. Essa equações de continuidade *account* para o fluxo dentro do volume, a criação de portadores com o volume (geração), e a aniquilação de portadores com o volume (recombinação).

**Equação 29.**

$$\frac{\partial n}{\partial t} = \frac{\nabla \bar{J}_n}{q} + G_l - U_n$$

Onde:

$\frac{\partial n}{\partial t}$ : Criação de portadores com o tempo.

$\nabla \bar{J}_n$ : Densidade de corrente do elétron (A.cm<sup>-2</sup>).

$q$ : Carga do Elétron (C).

$G_l$ : Taxa de geração dos pares elétron-lacuna.

$U_n$ : Taxa de recombinação dos elétrons.

**Equação 30.**

$$\frac{\partial p}{\partial t} = \frac{\nabla \bar{J}_p}{q} + G_l - U_p$$

Onde:

$\frac{\partial p}{\partial t}$ : Criação de portadores com o tempo

$\nabla \bar{J}_p$ : Densidade de corrente da lacuna (A.cm<sup>-2</sup>).

$q$ : Carga o Elétron (C).

$G_l$ : Taxa de geração dos pares elétron-lacuna.

$U_p$ : Taxa de recombinação das lacunas.

A Equação de Poisson para eletrostática provê a terceira equação independente.

**Equação 31.**

$$\nabla(\epsilon \nabla \psi) = -\rho$$

Onde:

$\epsilon$ : Permissividade (F.cm<sup>-3</sup>).

$\nabla\psi$ : Potencial (V).

$\rho$ : Densidade de Carga (C.cm<sup>-3</sup>).

A Equação de Poisson é satisfeita com o espaço discreto de elementos pela minimização da energia eletrostática total do sistema,  $W_e$ .

### Equação 32.

$$W_e = \int_0^W \frac{\epsilon}{2} \left[ \frac{\partial\psi}{\partial x} \right]^2 dx - \int_0^W \rho\psi dx$$

Onde:

$W_e$ : Energia eletrostática total do sistema (J).

$\epsilon$ : Permissividade (F.cm<sup>-3</sup>).

$\frac{\partial\psi}{\partial x}$ : Variação do potencia de acordo com a profundidade.

$\rho$ : Densidade de Carga (C.cm<sup>-3</sup>).

$\psi$ : Potencial (V).

A corrente do elétron é dada pela quase- uma dimensão em direção a solução dimensional.

### Equação 33.

$$I_n(x)\bar{a}_x = -q\mu_n(x, E)n(x)A(x)\nabla\phi_n(x)$$

Onde:

$I_n(x)$ : Corrente de transporte dos elétrons (A).

$\bar{a}_x$ :

$q$ : Carga do Elétron (C).

$\mu_n(x, E)$ : Mobilidade do elétron.

$n(x)$ : Concentração de elétrons em função da profundidade (átomos.cm<sup>-3</sup>).

$A(x)$ : Área (m<sup>2</sup>).

$\nabla\phi_n(x)$ : Potencial quase Fermi para os elétrons.

### Equação 34.

$$\mu(x, E) = \mu(x, 0) / \sqrt{1 + \left[ \frac{\mu(x, 0)E}{V_{sat}(x)} \right]^2}$$

Onde:

$\mu(x, E)$ : Mobilidade de portadores.

$\mu(x, 0)$ : Mobilidade de portadores na superfície.

$V_{sat}(x)$ : Velocidade de saturação (cm.s<sup>-1</sup>).

### Equação 35.

$$E = -\nabla\psi$$

Onde:

$E$ : Intensidade do campo elétrico.

$\psi$ : Potencial (V).

Definição do potencial elétrico modificado

**Equação 36.**

$$\xi_n(x) = \psi(x) + V_n(x) + \frac{KT}{q} \ln \frac{\mu_n(x, E) A(x)}{\mu_r A_r}$$

Onde:

$\xi_n$ : Potencial Elétrico no semiconductor tipo N (V).

$\psi$ : Potencial (V).

$V_n$ : Velocidade dos elétrons (cm.s<sup>-1</sup>).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$q$ : Carga do Elétron (C).

$\mu_n$ : Mobilidade dos elétrons.

$A$ : Área de seção transversal (cm).

$\mu_r$ : Mobilidade referencial.

$A_r$ : Área referencial.

**Equação 37.**

$$I_n(x) \overline{a_x} = -q \mu_r n_{ir} A_r \nabla \phi_n(x) e^{q(\xi_n(x) - \phi_n(x))/KT}$$

Onde:

$I_n(x)$ : Corrente de transporte do elétron (A).

$\overline{a_x}$ :

$q$ : Carga do Elétron (C).

$\mu_r$ : Mobilidade referencial.

$n_{ir}$ : Concentração intrínseca referencial.

$A_r$ : Área referencial.

$\nabla \phi_n(x)$ : Potencial quase Fermi para os elétrons.

$\xi_n(x)$ : Potencial Elétrico (V).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

**Equação 38.**

$$\int_{x_k}^{x_{k+1}} I_n(x) e^{-q\xi_n(x)/KT} dx = q D_r n_{ir} A_r \left[ e^{-q\phi_n(x_k)/KT} - e^{-q\phi_n(x_{k+1})/KT} \right]$$

Onde:

$I_n(x)$ : Corrente de transporte do elétron (A).

$q$ : Carga do Elétron (C).

$\xi_n(x)$ : Potencial Elétrico (V).

$K$ : Constante de Boltzmann.

$T$ : Temperatura (K).

$D_r$ : Difusidade referencial.

$n_{ir}$ : Concentração intrínseca referencial.

$A_r$ : Área referencial

$\phi_n$ : Potencial quase Fermi para os elétrons.