

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC

CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT

ENGENHARIA ELÉTRICA

CHRYSTIAN LENON REMES

**CARACTERIZAÇÃO POR SIMULAÇÃO NUMÉRICA DE PAINÉIS
FOTOVOLTAICOS E MÉTODO DE RASTREAMENTO DO MÁXIMO PONTO DE
POTÊNCIA BASEADO EM REDES NEURAIS ARTIFICIAIS.**

JOINVILLE, SC

2013

CHRYSTIAN LENON REMES

**CARACTERIZAÇÃO POR SIMULAÇÃO NUMÉRICA DE PAINÉIS
FOTOVOLTAICOS E MÉTODO DE RASTREAMENTO DO MÁXIMO PONTO DE
POTÊNCIA BASEADO EM REDES NEURAIS ARTIFICIAIS.**

Trabalho de conclusão apresentado ao
Curso de Engenharia Elétrica do Centro
de Ciências Tecnológicas, da
Universidade do Estado de Santa
Catarina, como requisito parcial para a
obtenção do grau de Bacharel em
Engenharia Elétrica.

Orientador: Sérgio Vidal Garcia Oliveira

JOINVILLE, SC

2013

CHRYSTIAN LENON REMES

**CARACTERIZAÇÃO POR SIMULAÇÃO NUMÉRICA DE PAINÉIS
FOTOVOLTAICOS E MÉTODO DE RASTREAMENTO DO MÁXIMO PONTO DE
POTÊNCIA BASEADO EM REDES NEURAIS ARTIFICIAIS.**

Trabalho de conclusão apresentado ao curso de Engenharia Elétrica do Centro de Ciências Tecnológicas, da Universidade Do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Banca Examinadora

Orientador: _____

Prof. Dr. Sérgio Vidal Garcia Oliveira

UDESC

Membro: _____

Prof^a. Dr^a. Mariana Santos Matos Cavalca

UDESC

Membro: _____

Prof. PhD. Yales Rômulo de Novaes

UDESC

Joinville SC, 02/07/2013

Aos meus pais, Paulo e Cida, à minha irmã
Paula, e aos meus familiares, por todo apoio
e afeto durante toda a minha vida, e por
acreditarem no meu trabalho.

Aos meus amigos, em especial aos de longa data, que acompanharam meu esforço e me suportaram nos momentos difíceis.

À minha amada Jéssica, por toda sabedoria,
paciência, companheirismo e carinho
durante todos os dias.

RESUMO

Considerando o atual ritmo de desenvolvimento mundial em termos tecnológicos e industriais, e o elevado índice de crescimento populacional paralelo às altas taxas de urbanização, vê-se como necessidade uma melhor eficiência na utilização dos recursos energéticos disponíveis e a priorização do uso de fontes alternativas de energia. Neste contexto, a otimização da potência dos sistemas fotovoltaicos em geral torna-se um quesito importante em termos energéticos, sendo que as técnicas utilizadas no Rastreamento do Máximo Ponto de Potência (MPPT) são as mais diversas possíveis, cada qual com suas vantagens e desvantagens. Neste trabalho, serão apresentados princípios básicos de funcionamento de módulos fotovoltaicos e a modelagem matemática das células fotovoltaicas, o módulo de simulação de um painel fotovoltaico no *software* PSIM e no *software* MATLAB, além de alguns algoritmos de MPPT. Será também visto um estudo fundamental de Redes Neurais Artificiais, que futuramente serão aplicadas como técnica para encontrar o Máximo Ponto de Potência (MPP) de painéis fotovoltaicos.

Palavras-chave: Eficiência Energética. Painéis Fotovoltaicos. MPPT. PSIM. Redes Neurais Artificiais. MATLAB.

ABSTRACT

Considering the recent rhythm of development in the world in terms of technology and industry, and the high rates of population growing parallel with the high rates of urbanization, has been seeing as a necessity a greater efficiency in the utilization of the energetic recourses available and the use of the alternative sources of energy as a priority. In this context, the optimization of the power in general photovoltaic systems becomes an important item on energetic terms, where the utilized techniques are the most diverse as possible in the Maximum Power Point Tracking (MPPT), each with their advantages and disadvantages. In this document, will be show the basic elements photovoltaic modules running and the mathematic modeling of the photovoltaic cells, the simulation module of a photovoltaic array on software PSIM and simulations using the software MATLAB, beyond some MPPT algorithms. Will be shown also a fundamental Artificial Neural Networks study, that after will be applied as a technique to find the Maximum Power Point (MPP) in photovoltaic panels.

Key-words: Energetic Efficiency, Photovoltaic Arrays, MPPT, PSIM, Artificial Neural Networks. MATLAB.

SUMÁRIO

LISTA DE FIGURAS.....	12
LISTA DE TABELAS.....	14
1 INTRODUÇÃO.....	15
2 SISTEMAS FOTOVOLTAICOS – ASPECTOS GERAIS E MODELAGEM MATEMÁTICA.....	19
2.1 O ARRANJO TÍPICO DE UM SISTEMA FOTOVOLTAICO	20
2.2 A GERAÇÃO DISTRIBUÍDA	21
2.3 A CÉLULA FOTOVOLTAICA	23
2.4 PRINCÍPIOS FÍSICOS DA CÉLULA FOTOVOLTAICA DE SILÍCIO ..	26
2.5 CIRCUITO EQUIVALENTE E MODELO MATEMÁTICO DE UMA CÉLULA FOTOVOLTAICA	29
2.6 VARIÁVEIS CLIMÁTICAS E CONDIÇÕES PADRÃO DE TESTE (STC) 30	
2.7 SISTEMAS DE ARMAZENAMENTO DE ENERGIA.....	31
3 SIMULAÇÃO DE PAINÉIS FOTOVOLTAICOS	33
3.1 SOLAR MODULE - PSIM	33
3.2 SOLAR MODULE (PHYSICAL MODEL) – UTILITY	36
3.3 MATLAB	37
3.4 PARÂMETROS PARA SIMULAÇÃO.....	39
4 O RASTREAMENTO DO MÁXIMO PONTO DE POTÊNCIA (MPPT)	42
4.1 ALGORITMOS DE MPPT.....	44
4.1.1 Perturba e Observa (P&O) e <i>Hill Climbing</i>	44
4.1.2 Condutância Incremental.....	45
4.1.3 Fração da Tensão de Circuito Aberto.....	46
4.1.4 Fração da Corrente de Curto-Circuito	46

4.1.5	Controle por Lógica Fuzzy.....	47
4.1.6	Redes Neurais Artificiais	47
4.1.7	Outras técnicas	48
4.1.8	Discussão.....	48
5	REDES NEURAS ARTIFICIAIS.....	49
5.1	INTELIGÊNCIA ARTIFICIAL	49
5.2	CARACTERÍSTICAS DAS REDES NEURAS	50
5.3	O NEURÔNIO BIOLÓGICO	51
5.4	O NEURÔNIO ARTIFICIAL	53
5.5	FUNÇÕES DE ATIVAÇÃO	54
5.6	ARQUITETURAS DE REDE	57
5.7	PROCESSOS DE APRENDIZADO	58
5.7.1	Aprendizado Supervisionado.....	59
5.7.2	Aprendizado Não-Supervisionado	60
5.7.3	Aprendizado por Reforço.....	61
5.8	APLICAÇÃO DE REDES NEURAS ARTIFICIAIS COMO TÉCNICA DE MPPT EM PAINÉIS FOTOVOLTAICOS	62
5.9	HIPÓTESES.....	62
6	OBTENÇÃO DOS PARÂMETROS DO PAINÉL FOTOVOLTAICO	64
6.1	DADOS DE CATÁLOGO DO PAINEL FOTOVOLTAICO UTILIZADO 64	
6.2	CÁLCULO DOS PARÂMETROS DO PAINEL FOTOVOLTAICO.....	65
6.2.1	Aproximação do Fator de Idealidade do Diodo e da sua Corrente de Saturação na Temperatura de Referência	66
6.2.2	Algoritmos genéticos para determinação das resistências.....	67
6.2.3	Cálculo das Constantes do Diodo	68
7	CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL	69
7.1	MULTI-LAYER PERCEPTRON E A TOPOLOGIA UTILIZADA.....	69

7.2	A BASE DE DADOS DE TREINAMENTO	70
7.3	A FASE DE TREINAMENTO.....	73
8	RESULTADOS.....	76
	CONCLUSÃO	81
	REFERÊNCIAS	83
A.	ANEXOS.....	87
A-I.	ALGORITMO DE OBTENÇÃO DE R_p E R_s ATRAVÉS DE ALGORITMOS GENÉTICOS.....	87
A-II.	FUNÇÃO QUE CALCULA A TENSÃO DE MÁXIMA POTÊNCIA DO PAINEL PARA UM DADO VALOR DE TEMPERATURA E RADIAÇÃO SOLAR: .	87
A-III.	REDE NEURAL ARTIFICIAL MLP COM FUNÇÃO DE ATIVAÇÃO SIGMOIDE – TREINAMENTO E VALIDAÇÃO	88

LISTA DE FIGURAS

Figura 1 - Crescimento demográfico mundial total e da população urbana. ...	15
Figura 2 - Ilustrativo do crescimento da população urbana mundial.	16
Figura 3 - Utilização das matrizes energéticas renováveis e não renováveis. ...	17
Figura 4 - Atlas mundial da radiação solar.	19
Figura 5 - Esquema típico de um coletor solar.	20
Figura 6 - Esquema genérico de um sistema fotovoltaico.	21
Figura 7 – Diagrama de blocos de um sistema fotovoltaico residencial conectado à rede.	22
Figura 8 - O consumo de energia e a geração fotovoltaica ao longo do dia. ...	23
Figura 9 - Aspectos construtivos de uma célula fotovoltaica.	24
Figura 10 - Foto de uma célula fotovoltaica de silício.	24
Figura 11 - Diferentes materiais utilizados na construção de células fotovoltaicas.	25
Figura 12 - Avanços tecnológicos na eficiência das células solares.	26
Figura 13 - Ilustração do processo de dopagem do silício.	27
Figura 14 - Região de depleção.	27
Figura 15 - Ilustrativo do efeito fotoelétrico.	28
Figura 16 - Circuito equivalente de uma célula fotovoltaica.	29
Figura 17 - PSIM e o <i>Solar Module (physical model)</i>	34
Figura 18 - Parametros do <i>Solar Module</i>	34
Figura 19 - <i>Solar Module (physical model) utility</i>	36
Figura 20 – Esquemático de uma célula solar no <i>Simulink</i>	37
Figura 21 – Exemplo de comando em MATLAB.	38
Figura 22 - Curvas características $I \times V$ em função de S e T	43
Figura 23 - Curvas características $P \times V$ em função de S e T	43
Figura 24 - Ilustrativo de um neurônio biológico.	51
Figura 25 - Forma de onda do potencial de ativação.	52
Figura 26 - Sinapse de um neurônio biológico.	52
Figura 27 - Representação de um neurônio artificial.	54
Figura 28 - Função Degrau.	55
Figura 29 - Função Sinal.	55

Figura 30 - Função Linear.....	55
Figura 31 - Função Sigmóide.....	56
Figura 32 - Função Tangente Hiperbólica.....	56
Figura 33 - Função Gaussiana.	56
Figura 34 - Malha de uma RNA treinada por aprendizado supervisionado.....	59
Figura 35 - Malha de uma RNA treinada por aprendizado não-supervisionado.	61
Figura 36 – Ilustração do painel fotovoltaico SW 130 Poly/R6A.	64
Figura 37 - Fluxograma de obtenção dos parâmetros do painel solar	66
Figura 38 – Representação da RNA MLP construída.	70
Figura 39 – Fluxograma do algoritmo de obtenção dos valores de V_{mpp} para o uso nas RNAs.	72
Figura 40 – Árvore de amostragem para simulações.	73
Figura 41 - Fluxograma do algoritmo de treinamento da RNA.....	74
Figura 42 - Fluxograma do algoritmo de validação da RNA.	75
Figura 43 - Número de épocas de treinamento utilizando função sigmóide. ..	76
Figura 44 - Número de épocas de treinamento utilizando função tangente hiperbólica.	77
Figura 45 - Tempo de execução do algoritmo de treinamento utilizando função sigmóide.	77
Figura 46 - Tempo de execução do algoritmo de treinamento utilizando função tangente hiperbólica.	78
Figura 47 – Média dos erros médios quadráticos em função do número de amostras de treinamento utilizando função de ativação sigmóide.	79
Figura 48 - Média dos erros médios quadráticos em função do número de amostras de treinamento utilizando função de ativação tangente hiperbólica.	79


LISTA DE TABELAS

Tabela 1 - Esquemático do algoritmo P&O / Hill Climbing.	44
Tabela 2 - Comparativo entre algumas técnicas de MPPT.	48
Tabela 3 - Dados de catálogo SW 130 Poly/R6A.	65
Tabela 4 - Parâmetros do painel fotovoltaico obtidos numericamente e analiticamente.	68

1 INTRODUÇÃO

Desde o último século, vive-se uma era de crescimento vertiginoso em termos populacionais e tecnológicos, sendo que tanto a população quanto a tecnologia tem suas parcelas isoladas de crescimento e, aliadas influenciam-se de maneira que um maior desenvolvimento tecnológico pode implicar em crescimento populacional (por exemplo, através do aumento da expectativa de vida) e vice-versa. A indústria, de forma geral, também vem acompanhando este ritmo acelerado de crescimento, sendo ancorada pelo desenvolvimento de novas tecnologias e novos meios de produção, e amparada pelo aumento do consumo de seus produtos. Na Figura 1, pode-se analisar o crescimento demográfico mundial, e também o crescimento da população urbana mundial.


Figura 1 - Crescimento demográfico mundial total e da população urbana.



Fonte: OECD.

Segundo o relatório de prospecção de urbanização mundial (World Urbanization Prospects) da ONU de 2011 [1], atualmente tem-se aproximadamente 50% da população mundial vivendo em zonas urbanas, e este número deve aumentar para cerca de 67% até 2050, conforme ilustrado na Figura 2.

Figura 2 - Ilustrativo do crescimento da população urbana mundial.



Fonte: Adaptado de CBPE, 2012.


Essa associação de fatores como os avanços tecnológicos, o aumento dos setores industriais, o crescimento no número de habitantes no planeta e de moradores nas zonas urbanas, além do crescimento do consumo geral de produtos, acarreta num incremento progressivo sobre a demanda de energia. Neste âmbito, o desenvolvimento sustentável deve atuar fortemente, fornecendo os meios necessários à melhoria da qualidade de vida da população com a minimização dos impactos causados ao meio ambiente.

Frente às principais matrizes energéticas renováveis que atendem ao desenvolvimento sustentável, surge a geração de energia fotovoltaica. Proveniente da conversão direta da energia irradiada pelo sol em eletricidade, os painéis fotovoltaicos podem se tornar uma das principais fontes de energia do mundo, sem qualquer emissão de poluentes atmosféricos, ruídos, ou quaisquer tipos de agressores ambientais, agregando ainda a vantagem de possibilitar a técnica de geração distribuída de energia elétrica.

Atualmente, a matriz energética mundial está longe da utilização massiva de fontes de energia renováveis, sendo o Brasil um país de destaque na utilização destes tipos de recursos, porém, há ainda uma grande dependência energética de fontes não-renováveis, em especial combustíveis fósseis como os derivados do petróleo e o carvão mineral, como mostra a Figura 3. A razão do ano de 2011

possuir uma menor porcentagem na utilização de matrizes renováveis é devida ao aumento do preço do etanol, que resultou num maior consumo de combustíveis fósseis no setor de transportes [2].

Figura 3 - Utilização das matrizes energéticas renováveis e não renováveis.



Fonte: Adaptado do BEN, 2012.

Deve-se ainda salientar a importância dos sistemas eficientes para que haja o desenvolvimento sustentável. Segundo QUEIROZ, em 2009 as perdas ocasionadas pela transmissão e distribuição de energia elétrica no sistema brasileiro chegaram a quase 12% em relação à energia total injetada (sendo desconsideradas as perdas ocasionadas por furtos e erros de medição calculados por estimativas). Neste escopo, se pode pensar na geração distribuída como uma alternativa para a diminuição das perdas ocasionadas pela transmissão e distribuição de energia, aumentando assim a eficiência energética do sistema.

É evidente como a geração fotovoltaica pode agregar inúmeros benefícios por se tratar de uma opção ambientalmente viável e totalmente condizente com os novos padrões de vida sustentados pela humanidade ultimamente. E muito do que foi desenvolvido até hoje em termos tecnológicos de sistemas fotovoltaicos se deve ao avanço alcançado pela eletrônica de potência, que é necessária ao processamento de energia, como melhor apresentado por COELHO, que também cita sobre a importância dos conversores utilizados no rastreamento do máximo ponto de potência [4].

Na maior parte das aplicações, a eletrônica de potência é utilizada com o objetivo de processar os níveis de tensão e corrente de entrada, tornando-os adequados para alimentar uma carga específica. No caso de cargas em corrente contínua, são utilizados os conversores CC-CC e, no caso de cargas em corrente alternada, os conversores CC-CA, comumente chamados inversores.

Em muitas aplicações, o conversor é utilizado entre o módulo fotovoltaico e a carga, não somente para mantê-la adequadamente alimentada, mas também para permitir que o módulo atue sempre no ponto de máxima transferência de potência. Este tipo de aplicação é tão importante que, na literatura, os conversores utilizados com esta finalidade são especialmente denominados de rastreadores de máxima potência [4].

O rastreamento do máximo ponto de potência de um painel fotovoltaico é um requisito chave para que se possa obter do mesmo uma melhor eficiência na transformação de energia solar em energia elétrica, além do tipo de tecnologia utilizada na fabricação do painel. Sendo assim, é importante que se busque uma melhoria na eficiência de painéis fotovoltaicos tanto em relação aos seus aspectos construtivos quanto no método de rastreamento do máximo ponto de potência utilizado, promovendo assim melhores fontes geradoras de energia elétrica, que possam atender melhor à crescente demanda de energia em todo mundo.


Na seção 2, serão mostrados os sistemas fotovoltaicos, os aspectos construtivos de uma célula fotovoltaica e seu princípio de funcionamento, e outras generalidades sobre painéis fotovoltaicos. Na seção 3, pode ser vista uma visão geral sobre os *softwares* de simulação de painéis fotovoltaicos. Na seção 4 serão apresentados os principais aspectos do rastreamento do máximo ponto de potência de um painel fotovoltaico e um comparativo entre alguns dos métodos já existentes. Na seção 5, as redes neurais artificiais são brevemente apresentadas. A partir da seção 6, são demonstrados os resultados obtidos neste trabalho, desde a obtenção dos parâmetros necessários para a simulação do painel fotovoltaico, até a construção da rede neural artificial e sua utilização como ferramenta para o rastreamento do máximo ponto de potência, bem como os resultados obtidos através da simulação de redes neurais artificiais atuando no rastreamento do máximo ponto de potência.

2 SISTEMAS FOTOVOLTAICOS – ASPECTOS GERAIS E MODELAGEM MATEMÁTICA

A energia solar compõe-se de toda e qualquer forma de aproveitar ou transformar a energia luminosa proveniente do sol em qualquer outra fonte utilizável pelo homem, como a energia elétrica, térmica, mecânica entre outras, sendo inesgotável na escala de tempo humana [5].

Quase todas as fontes de energia existentes em nosso planeta são fontes diretas ou indiretas da energia solar, afinal, é esta que sustenta o ciclo da água necessário às hidrelétricas, o ciclo dos ventos que movimenta as pás de um aerogerador, além de manter a temperatura da atmosfera terrestre que proporciona a existência de seres vivos e de ser fundamental no processo de fotossíntese de algas e plantas, base de toda cadeia alimentar terrestre. Assim, o sol é a nossa matriz energética primitiva, proporcionando ao planeta outras formas de aproveitamento desta energia que aqui é depositada. Na Figura 4, pode-se ver o mapa da radiação solar em todo mundo no ano de 2006 [6].

Figura 4 - Atlas mundial da radiação solar.




Fonte: DForceSolar.

Dentre as formas diretas de aproveitamento de energia solar, pode-se destacar o aproveitamento térmico e o aproveitamento elétrico direto. Na utilização direta da energia térmica, são utilizados coletores solares, ilustrados na Figura 5, que absorvem a radiação solar e são utilizados principalmente no aquecimento de água. O uso desta tecnologia ocorre de maneira massiva nas residências, mas também pode ser utilizado por hospitais, indústrias, entre outros.

Além disso, podem ser usados concentradores solares, que são nada mais que espelhos parabólicos que concentram a luz em seu foco, e esta poderá então aquecer a água a temperaturas substancialmente elevadas, possibilitando assim o seu emprego em usinas de geração térmica. No caso da conversão direta de energia luminosa em energia elétrica, o processo se dá através das chamadas células fotovoltaicas, que serão melhor discutidas nos tópicos adiante.

Figura 5 - Esquema típico de um coletor solar.



Fonte: ANEEL, 2008.


2.1 O ARRANJO TÍPICO DE UM SISTEMA FOTOVOLTAICO

Os sistemas fotovoltaicos podem ser classificados em sistemas isolados, sistemas conectados à rede ou ainda em sistemas híbridos.

Nos sistemas isolados geralmente existe uma forma de armazenamento de energia, que pode se dar por meio de baterias ou por sistemas de bombeamento de água para tanques de abastecimento para armazenamento de energia na forma potencial gravitacional. Em sistemas com baterias, estas são providas de um controlador de carga, que controla os processos de carga e descarga da mesma. Para que haja alimentação de cargas CA, são utilizados inversores de frequência.

Já os sistemas interligados à rede não fazem o armazenamento de energia, pois toda a energia excedente gerada é injetada na rede elétrica, atuando assim como uma espécie de geração complementar. Os sistemas híbridos, por fim, são sistemas compostos pelas duas arquiteturas descritas acima [6].

Figura 6 - Esquema genérico de um sistema fotovoltaico.




Fonte: Adaptado de CRESEB, 2006.

2.2 A GERAÇÃO DISTRIBUÍDA

Uma das grandes vantagens da utilização de sistemas fotovoltaicos para geração de energia é a possibilidade de se concentrar as unidades geradoras muito próximas dos grandes centros de carga, podendo estas serem usinas de maior potência próximas às cidades ou mesmo módulos isolados instalados em edifícios ou em residências para consumo próprio. Esta topologia de geração dispensa o uso de grandes linhas de transmissão e de distribuição, diminuindo suas respectivas perdas [5]. Além destas vantagens, vêm crescendo nestes últimos anos a adoção de

Outra característica marcante da geração através de arranjos fotovoltaicos é que estes tem sua maior produção de energia durante o dia, que é justamente um dos principais momentos em que o sistema elétrico necessita de uma grande quantidade de injeção de potência. Assim, a utilização da geração distribuída, com auxílio da geração fotovoltaica, poderia ser uma grande aliada do sistema elétrico, desfogando-o nos horários de maior consumo e permitindo um melhor manejo de operação do mesmo, conforme exemplo mostrado na Figura 8.

Figura 8 - O consumo de energia e a geração fotovoltaica ao longo do dia.




Fonte: PEREIRA, 2010.

2.3 A CÉLULA FOTOVOLTAICA

Também conhecidas por células solares ou células fotoelétricas, estas se baseiam no fenômeno físico chamado efeito fotoelétrico. Estas células são fabricadas com materiais semicondutores, sendo as mais empregadas àquelas feitas a base de silício (Si). No silício em sua forma mais pura, também chamado de silício intrínseco, os átomos se combinam em cristais estáveis, pois não há sobra nem

déficit de elétrons. Este material necessita de um processo chamado de dopagem, onde é adicionado ao silício intrínseco elementos trivalentes (geralmente Boro) ou pentavalentes (geralmente Fósforo), que formarão os chamados substratos tipo p e n, respectivamente. O funcionamento físico dos semicondutores será explicado posteriormente. Na Figura 9 pode-se ver a estrutura de uma célula fotovoltaica em detalhes e na Figura 10 tem-se uma foto de uma célula solar [8].

Figura 9 - Aspectos construtivos de uma célula fotovoltaica.



Fonte: Adaptado de How Stuff Works, 2000.

Figura 10 - Foto de uma célula fotovoltaica de silício.




Fonte: Solarpedia.

Outros materiais também foram sendo desenvolvidos para aplicação direta em células solares. Na Figura 11 são mostradas três classes de células que são

produzidas nos dias de hoje, sendo elas distinguidas ainda em primeira, segunda e terceira geração.

Figura 11 - Diferentes materiais utilizados na construção de células fotovoltaicas.




Fonte: COELHO, 2008.

A terceira geração de células solares merece destaque, pois faz parte de uma das mais novas tecnologias existentes, a das células de multijunção, podendo estas serem construídas a partir de duas, três ou quatro junções semicondutoras, ao invés de uma única. Estas células tem capacidade de absorver uma gama maior de comprimentos de onda, e por consequência sua eficiência é aumentada para cerca de 40%, praticamente o dobro da eficiência das células de Silício comerciais, que chegam na casa dos 20%.

A busca por novos materiais e tecnologias construtivas das células fotovoltaicas tem alcançado o aumento de eficiência na conversão da energia solar, como visto na Figura 12.

Figura 12 - Avanços tecnológicos na eficiência das células solares.



Fonte: COELHO, 2008.


2.4 PRINCÍPIOS FÍSICOS DA CÉLULA FOTOVOLTAICA DE SILÍCIO

O princípio básico de funcionamento de uma célula fotovoltaica é utilizar-se do efeito fotoelétrico sobre uma junção pn para produção de uma corrente elétrica. A junção pn caracteriza-se pela união de dois substratos tipo n e p, que são obtidos através da dopagem do silício puro. Na Figura 13 está ilustrado o processo de dopagem, onde pode-se visualizar que a adição de átomos trivalentes ao silício cria uma lacuna (falta de elétrons) que resulta em um substrato tipo p, enquanto que a adição de átomos pentavalentes faz com que haja elétrons em excesso, que é a característica do substrato tipo n.

Quando unidos, os dois substratos irão alocar alguns dos elétrons do substrato n nas lacunas do substrato p. Essa alocação acontecerá apenas numa


faixa estreita entre os dois materiais, chamada de região de depleção, que originará um campo elétrico em seu interior e consequentemente uma tensão de junção, que não deixará com que o restante dos elétrons se aloque nas lacunas restantes, processo este ilustrado na Figura 14 [8].

Figura 13 - Ilustração do processo de dopagem do silício.



Fonte: Adaptado de Scandig.

Figura 14 - Região de depleção.



Fonte: Adaptado de Rodolfo Ferraz.

Da junção pn tem-se dois substratos carregados com cargas opostas e a região de depleção atuando como barreira à passagem destas cargas. Então, para que os elétrons do substrato n possam transpor a região de depleção até o substrato p basta que seja dada uma energia a estes elétrons. E é aqui que a radiação luminosa atua, dando energia aos elétrons para que estes possam circular do substrato n ao p, gerando uma corrente elétrica.


A teoria da dualidade onda-partícula diz que a luz pode se comportar ora como onda, no caso da radiação eletromagnética, e ora como partícula, na forma de pequenos pacotes discretos de energia chamados fótons. A energia dos fótons é

proporcional à frequência da onda eletromagnética, como descrito na Equação (2.1), onde $h = 4.138 \times 10^{-15} eV$ e representa a constante de Planck.

$$E_{fóton} = hf \quad (2.1)$$

Quando uma célula fotovoltaica é exposta a luz solar, os fótons chocam-se aos elétrons da placa, fornecendo-lhes energia. Desde que a energia contida nos fótons seja maior que àquela imposta pela barreira da região de depleção, os elétrons entrarão em movimento, gerando uma corrente elétrica. É este o fenômeno conhecido por efeito fotoelétrico e está ilustrado na Figura 15.

Figura 15 - Ilustrativo do efeito fotoelétrico.



Fonte: Efeito Fotoelétrico.


É como se os fótons batessem nos elétrons, e esta batida gerasse um impulso que movimenta estes elétrons, mas isso só ocorre se a batida do fóton contiver energia suficientemente maior que a energia que mantém os elétrons na sua forma estática atual. Caso contrário, a energia absorvida não será convertida em movimento, mas sim em energia térmica, aumentando a vibração dos elétrons do material. Sabe-se que a função trabalho da placa de silício é de $1.12 eV$, e para que haja fluxo de elétrons, deve-se ter $E_{fóton} = hf > 1.12$. Isolando-se a frequência nesta expressão, obtém-se que a frequência mínima para que o efeito fotoelétrico ocorra numa chapa de silício é $f = 270.66 \times 10^{12} Hz$, ou seja, qualquer frequência superior ao espectro de infravermelho garante a geração de corrente elétrica numa célula de silício. [8]

2.5 CIRCUITO EQUIVALENTE E MODELO MATEMÁTICO DE UMA CÉLULA FOTOVOLTAICA

Pode-se entender fisicamente uma célula fotovoltaica como uma junção pn que, quando exposta a radiação solar, é capaz de gerar corrente elétrica, como já foi relatado anteriormente. Baseado nestes aspectos, pode-se representar a energia gerada pelo efeito fotoelétrico como uma fonte de corrente I_{ph} em paralelo a um diodo que representa a junção pn. Deve-se ainda considerar que existem perdas internas ou por correntes de fuga, que aqui serão representadas por um resistor em paralelo R_p , e também perdas decorrentes dos condutores metálicos apresentadas na forma de um resistor em série R_s . Através destes parâmetros obtém-se o circuito da Figura 16. [8]

Alguns autores tem proposto modelos mais sofisticados que podem representar as características do painel com maior precisão e podem servir para diferentes propósitos. Como exemplo, podem ser usados os modelos com dois ou três diodos, no lugar do diodo único utilizado neste trabalho, com a finalidade de modelar o efeito de recombinação dos elétrons e lacunas [9]. Neste trabalho o modelo de diodo único será o utilizado por questões de simplicidade.

Figura 16 - Circuito equivalente de uma célula fotovoltaica.



Fonte: Produção do próprio autor.

Através das correntes do circuito, tem-se que:

$$I = I_{ph} - I_D - I_p \quad (2.2)$$

$$\text{onde, } I_D = I_S \left(e^{\frac{1}{T} \left(\frac{q}{Ak} \right) (V + R_s I)} - 1 \right) \quad (2.3)$$

Sendo q a constante de carga elementar, A é um fator dependente da junção pn, k a constante de Boltzmann, T a temperatura da junção e I_r é a corrente de saturação reversa do diodo. Esta última é uma função da temperatura da junção T , e também da temperatura de referência T_r , além da energia acumulada na região de depleção E_g e da corrente de referência de saturação do diodo I_{So} , tal como:

$$I_S = I_{So} \left(\frac{T}{T_r} \right)^3 e^{\frac{q}{Ak} E_g \left(\frac{1}{T} - \frac{1}{T_r} \right)} \quad (2.4)$$

Por fim, há a necessidade de saber a corrente de curto circuito I_{sc} e a tensão de circuito aberto V_{oc} nas condições de referência de temperatura e radiação solar, tanto para determinação da corrente I_{ph} , apresentada em (2.6), gerada pelo efeito fotoelétrico quanto para determinação de I_{So} , mostrada em (2.5). Em geral, alguns dos dados citados são fornecidos pelo fabricante. Através de uma simples aproximação, considerando-se $I_{ph} \approx I_{sc}$, e considerando as condições climáticas de referência para temperatura e radiação solar, que serão melhor discutidas a diante, a corrente de saturação do diodo na temperatura de referência pode ser isolada, onde tem-se facilmente que:

$$I_{So} = \frac{I_{sc} - \frac{V_{oc}}{R_p}}{e^{\frac{q}{Ak} \left(\frac{V_{oc}}{T_r} \right)} - 1} \quad (2.5)$$

$$I_{ph} = (I_{sc} + KT_i(T - T_r)) \frac{S}{S_r} \quad (2.6)$$

Onde S_r é a radiação solar de referência na superfície do módulo solar, S a radiação solar instantânea e KT_i é uma constante de relação entre a corrente do painel e a temperatura, valor também catalogado [8].

2.6 VARIÁVEIS CLIMÁTICAS E CONDIÇÕES PADRÃO DE TESTE (STC)

Para a obtenção dos parâmetros de referência utilizados na modelagem matemática do painel solar, foram estabelecidas as Condições Padrão de Teste (ou STC – *Standard Test Conditions*), que zelam pela padronização por parte dos fabricantes dos valores de radiação solar, temperatura e massa de ar.

A radiação solar diz respeito à potência das ondas eletromagnéticas incidentes na superfície da célula fotovoltaica, medida em W/m^2 . Logo, fatores como sombreamento, principalmente ocasionados pelas nuvens, chuva e horário do dia, influenciam drasticamente nesta variável. Em geral, de todos os $1366 W/m^2$ médios de radiação que chegam à superfície terrestre, somente $1000 W/m^2$ atingem efetivamente a superfície da Terra sob a forma de radiação direta.

A temperatura é a medida do grau de agitação (vibração) dos átomos e moléculas. No meio microscópico, esta é uma variável que afeta muito as condições de operação de semicondutores e até de condutores, como pode-se observar através das equações já descritas anteriormente.

Por fim, o índice AM (*Air Mass* ou Massa de Ar) corresponde à massa de ar atmosférico que a radiação deve atravessar para incidir sobre a superfície terrestre. Matematicamente, o índice AM é descrito como sendo o inverso do cosseno do ângulo formado entre a terra e o raio incidente, ou seja:

$$AM = \frac{1}{\cos(\theta)} \quad (2.7)$$

As STCs estipulam que os valores de radiação, temperatura e AM de referência devem ser, respectivamente, $S_r = 1000 W/m^2$, $T_r = 25^\circ C$ e $AM_r = 1,5$ [8].

2.7 SISTEMAS DE ARMAZENAMENTO DE ENERGIA

Os sistemas de armazenamento de energia elétrica têm um papel importante nos sistemas fotovoltaicos, pelo fato que só é possível aproveitar tal energia durante o período diurno. As formas mais comuns de armazenamento de energia são os armazenadores eletroquímicos e os armazenadores eletromecânicos.

Armazenadores eletromecânicos são também conhecidos por *flywheel*, (sistema de massa girando em alta velocidade) e o armazenamento é feito na forma de energia cinética da massa girante. A energia cinética E_c é uma função do momento de inércia da massa J e da sua velocidade angular de rotação ω , sendo dada por:

$$E_c = J\omega^2 \quad (2.8)$$

Já os armazenadores eletroquímicos são as baterias, sendo que cada tipo pode ter diferentes densidades de energia por volume. A bateria é um dos elementos mais importantes em sistemas solares isolados, pois ela permite a integração no sistema de controle de otimização de potência máxima gerada no painel solar, fazendo-o se adequar ao comportamento da carga [10].

3 SIMULAÇÃO DE PAINÉIS FOTOVOLTAICOS


A simulação computacional é uma etapa importante a ser realizada em qualquer projeto, pois permite avaliar a viabilidade do mesmo e alguns dos possíveis problemas práticos que serão encontrados durante a implementação.

No caso do painel solar, o *software* PSIM é uma excelente ferramenta de simulação, podendo esta ser realizada através de um módulo já pronto ou através da construção de um circuito equivalente. Além do PSIM, o MATLAB também mostra-se uma excelente ferramenta que pode ser utilizada para a simulação de painéis fotovoltaicos.

3.1 SOLAR MODULE - PSIM

Dois tipos de módulos solares são fornecidos pelo PSIM. O *functional module* necessita de poucas variáveis a serem conhecidas e não depende dos sinais representativos de temperatura e radiação solar. Já o *physical module* requer um número maior de variáveis do painel disponíveis e dos valores de temperatura e radiação solar, mas também permite uma simulação com resultados mais precisos. A Figura 17 mostra a tela do software PSIM com um elemento *Solar Module (physical model)* inserido. [11]

Figura 17 - PSIM e o Solar Module (physical model).




Fonte: Produção do próprio autor.

Os sinais de temperatura e radiação solar a serem inseridos podem ser feitos simplesmente através de fontes de tensão que possuem a forma de onda dos respectivos sinais.

Quando são analisados os atributos do elemento do painel solar presente no esquemático, a tela exibida é mostrada na Figura 18.

Figura 18 - Parametros do Solar Module.



Fonte: Produção do próprio autor.

Nesta tela, vê-se que o módulo de simulação do painel depende de onze variáveis para que possa então ser utilizado.

Number of Cells N_s : É o número de células que compõe o painel solar.

Standart Light Intensity S_0 : É a referência de radiação solar dada em $[W/m^2]$ que será utilizada para as simulações. Em geral, será utilizado $S_0 = 1000 \text{ W/m}^2$ (STC).

Ref. Temperature T_{ref} : É a referência de temperatura dada em $[^\circ C]$ que será utilizada para as simulações. Em geral, será utilizado $T_{ref} = 25 \text{ }^\circ C$ (STC).

Series Resistance R_s : É a resistência série dada em $[\Omega]$ da célula do modelo do painel, a princípio desconhecida.

Shunt Resistance R_{sh} : É a resistência paralela R_p dada em $[\Omega]$ da célula do modelo do painel, a princípio também desconhecida.

Short Circuit Current I_{sc0} : Corrente de curto circuito de cada célula do módulo solar dada em $[A]$ obtida nas condições de referência (STC). Pode ser encontrada no catálogo do fabricante do módulo solar.

Saturation Current I_{s0} : Corrente de saturação do semicondutor de cada célula do painel solar em $[A]$ na temperatura de referência T_{ref} . A princípio é desconhecida.

Band Energy E_g : É a energia do campo elétrico da região de depleção de cada célula dada em $[eV]$. Depende do material utilizado (p.e. 1,12 eV para a célula de silício cristalino).

Ideality Factor A : Fator de idealidade do diodo (semicondutor). A princípio não é conhecido.


Temperature Coefficient C_t : Coeficiente de temperatura KT_i dada em $[A/^\circ C]$. Dado pelo catálogo do fabricante, representa a variação da corrente do painel em função da temperatura, conforme equação (2.6).

Coefficient K_s : Coeficiente que relaciona a variação da temperatura do painel de acordo com a radiação incidente dada em $[^\circ C.m^2/W]$.

3.2 SOLAR MODULE (PHYSICAL MODEL) – UTILITY

Existe ainda uma *Utility* do PSIM que é capaz de obter os parâmetros necessários à simulação de uma forma mais simples e intuitiva. Basta que sejam conhecidos os valores de catálogo do módulo solar, além do semiconductor utilizado no painel para que seja conhecido o valor de E_g , e o valor de A pode ser encontrado rapidamente também com os valores de catálogo através da Equação (3.6), que será apresentada na seção 3.4. Clicando em *Calculate Parameters*, os parâmetros desconhecidos da célula fotovoltaica como R_s , I_{s0} e KT_i são rapidamente calculados. Além disso, essa *utility* ainda traça a curva corrente por tensão e potência por tensão para que os valores dos parâmetros obtidos possam também validar o modelo simulado com facilidade. Na Figura 19 é mostrado um exemplo de utilização desta ferramenta.

Figura 19 - Solar Module (physical model) utility.




Fonte: Produção do próprio autor.

3.3 MATLAB

O MATLAB é uma ferramenta poderosa para a realização de simulações de painéis fotovoltaicos. Através dele, pode-se simular células solares através do *Simulink*, como mostrado na Figura 20 ou através de comandos, conforme Figura 21.

Figura 20 – Esquemático de uma célula solar no *Simulink*.



Fonte: Produção do próprio autor.

Figura 21 – Exemplo de comando em MATLAB.

```

1 - clear all
2 - clc
3 - %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
4 - %calculating parameters through the datasheet
5
6 - %Informing parameters:
7 - Ns = 36; %Number of cells in series
8 - Pmpp = 130; %Pot on MPP
9 - Voc = 21.9; %V circuito aberto
10 - Vmpp = 17.7; %V on MPP
11 - Isc = 7.65; %I curto-circuito
12 - Impp = 7.38; %I on mpp
13 - TCv = -0.34; % %/K - Voc
14 - TCi = 0.034; % %/K - Isc
15 - %KT = 0.0065; %KT (A/K) from graphic (possibly wrong)
16 - Eg = 1.12; %Band Gap Si (mono, poli, amorf)
17 - q = 1.60218e-19; %Elementary Charge (C)
18 - Kbolt = 1.38065e-23; %Cte Boltzman
19 - Tr = 25; %T no STC (°C)
20 - Tr = Tr + 273.16; %T em K
21 - Sr = 1000; %S no STC (W/m2)
22 - Vtr = Kbolt*(Tr)/q; %Vtr em V
23
24 - %Obtained Parameters (Angelo)
25 - %Rs = 100e-5;
26 - %Rp = 4.6e3;
27 - %Obtained Parameters (Chrystian GA)
28 - Rs = 3.7851e-5;
29 - Rp = 7.4175e7;
30
31 - %Calculating Parameters
32 - A = ((Vmpp-Voc)/36)/(Vtr*log((Isc-Impp-Vmpp/(36*Rp))/(Isc-Voc/(36*Rp)))

```

Fonte: Produção do próprio autor.

3.4 PARÂMETROS PARA SIMULAÇÃO

De todos os parâmetros que compõe o modelo matemático de um painel solar já apresentados acima, quatro ainda necessitam ser determinados caso a *Utility Physical Module* do PSIM não seja usada: R_s , R_p , I_{so} , A .

Em geral, os fabricantes disponibilizam alguns poucos dados que podem ser úteis na obtenção dos demais parâmetros necessários para simulação e até mesmo para caracterização do painel: a tensão e corrente no ponto de máxima potência (V_{mpp} e I_{mpp}), a tensão de circuito aberto e a corrente de curto circuito (V_{oc} e I_{sc}), as constantes de variação de tensão e corrente em função da temperatura (KT_v , KT_i) e a potência máxima (P_{max}) teórica, todos obtidos nas condições padrão (STC). [12]

A corrente de saturação do semicondutor e o fator de idealidade podem ser encontrados facilmente por meios analíticos através dos dados de catálogo. Para encontrar a corrente de saturação I_{so} , deve-se ter em mente que da equação (2.2) em circuito aberto, tem-se $I_{ph} = I_D + \frac{V_{oc}}{R_p}$. Considerando $I_{ph} \approx I_{sc}$, tem-se $IR_s \approx 0$, ou seja, $v_d \approx V_{oc}$, basta isolar I_{so} da equação da corrente do diodo (2.3) que chega-se em:

$$I_{so} = \frac{I_{sc} - \frac{V_{oc}}{R_p}}{e^{\frac{V_{oc}}{AV_T}} - 1} \quad (3.1)$$

Uma vez que o valor da corrente de saturação do diodo na condição de referência I_{so} é encontrado através de (3.1), pode-se encontrar o valor do fator de idealidade do diodo A , que é dependente deste parâmetro I_{so} .

Utilizando-se da Equação (2.2), com a corrente do diodo (2.3) já substituída, e considerando-se a operação em STC, tem-se que $I_s = I_{so}$, conforme Equação (2.4), resultando assim em (3.2):

$$I = I_{ph} - I_{so} \left(e^{\frac{V}{AV_T}} - 1 \right) - \frac{v_d}{R_p} \quad (3.2)$$

Usando-se I_{so} da equação (3.1), e já substituindo os valores de catálogo de máxima potência, o que sugere a consideração de que o ponto de operação utilizado

é o ponto de máxima potência no STC, de forma que $I = I_{mpp}$ e portanto $V = V_{mpp}$, chega-se na Equação (3.3):

$$I_{mpp} = I_{sc} - \left(I_{sc} - \frac{V_{oc}}{R_p} \right) \frac{\left(e^{\frac{V_{mpp}}{AV_T}} - 1 \right)}{\left(e^{\frac{V_{oc}}{AV_T}} - 1 \right)} - \frac{v_d}{R_p} \quad (3.3)$$

Sendo os valores de V_{oc} e V_{mpp} de cada célula em geral bem maiores que V_T em STC, as seguintes aproximações se tornam válidas: $e^{\frac{V_{mpp}}{AV_T}} \gg 1$ e $e^{\frac{V_{oc}}{AV_T}} \gg 1$. Logo, a equação (3.3) pode ser aproximada pela seguinte expressão:

$$I_{mpp} = I_{sc} - \left(I_{sc} - \frac{V_{oc}}{R_p} \right) \frac{\left(e^{\frac{V_{mpp}}{AV_T}} \right)}{\left(e^{\frac{V_{oc}}{AV_T}} \right)} - \frac{v_d}{R_p} \quad (3.4)$$

E por fim, considerando que a queda de tensão na resistência série é muito pequena, pode-se desprezá-la validando-se a seguinte aproximação:

$$v_d \approx V_{mpp} \quad (3.5)$$

Substituindo (3.5) em (3.4) e isolando o termo A , finalmente tem-se:

$$A = \frac{V_{mpp} - V_{oc}}{V_T \ln \left(\frac{I_{sc} - I_{mpp} - V_{mpp}/R_p}{I_{sc} - V_{oc}/R_p} \right)} \quad (3.6)$$

É importante salientar que os valores aqui obtidos em (3.1) e (3.6) levam em conta uma única célula fotovoltaica. Para a obtenção destas constantes para um painel como um todo, deve-se dividir todas as tensões presentes nas equações pelo número de células em série N_s .

Já para a obtenção dos parâmetros R_s e R_p , não há solução analítica pois $I = f(V, I)$ e $V = g(I, V)$. Esta equação transcendental, onde uma função depende do seu próprio valor, deve ser resolvida por métodos numéricos a fim de encontrar como solução R_s e R_p [13].

O método iterativo baseia-se na ideia de que R_s é muito pequeno e o inicializa em zero, valor que é incrementado lentamente, e então a equação $g(I, V) = P_{mpp} -$

$f(V,I).g(V,I) = 0$ é resolvida repetidamente para vários valores de I e V e variando-se R_p . Haverá apenas um ponto onde a tensão e a corrente multiplicadas resultarão na máxima potência a ser extraída pelo painel, que é o ponto onde R_s e R_p correspondem a solução [9].

Com relação ao o coeficiente K_s , este trata-se apenas da variação de temperatura de junção no painel em função da radiação solar, e pode ser seguramente desconsiderado, o que resulta em considerar que a temperatura ambiente é a própria temperatura de junção. Assim, seu valor será considerado sempre zero neste trabalho.

4 O RASTREAMENTO DO MÁXIMO PONTO DE POTÊNCIA (MPPT)

Em arranjos fotovoltaicos, a tensão e a corrente de saída variam instantaneamente em função da temperatura ambiente e da radiação solar, fazendo-se necessário o uso de sistemas que garantam a operação do painel em seu ponto máximo de potência instantâneo [14]. Estes sistemas são denominados de MPPT (*Maximum Power Point Tracking*). Os sistemas de MPPT podem ser divididos em duas partes [8]:

- Um algoritmo que recebe leituras do arranjo e executa cálculos que definem o ponto de máxima potência;
- Um estágio de potência responsável por fazer com que os painéis trabalhem no ponto de operação obtido.


Estas técnicas de MPPT visam à utilização de todo o potencial energético aproveitável que pode ser gerado pelo painel fotovoltaico, independente das condições climáticas e até mesmo de fatores inerentes ao próprio painel como seu envelhecimento.

A curva característica de corrente por tensão de um painel solar tem características bem peculiares. Para valores mais baixos de tensão, o painel mantém um comportamento de corrente aproximadamente constante, ou seja, o painel tem característica de fonte independente de corrente e pode admitir qualquer tensão nesta faixa. Porém, quando o limite de potência do painel é atingido, este começa a perder potência com o incremento de tensão. Isto se deve ao fato de a corrente do painel decrescer com o aumento de tensão [8].

A análise acima é válida independente dos valores de temperatura e radiação solar. O que deve ser levado em conta é que, a variação destes dois parâmetros não altera o “comportamento” tensão versus corrente do painel em si, mas sim reduz ou aumenta os valores absolutos de potência em toda faixa de tensão (ou corrente). Na Figura 22 podem ser vistas as diferentes curvas de corrente por tensão traçadas para diferentes valores de radiação solar e temperatura. Na Figura 23 pode-se observar o comportamento da potência em função da tensão também para


diferentes valores de radiação solar e temperatura, levando-se em consideração o modelo deste trabalho.

Figura 22 - Curvas características $I \times V$ em função de S e T .



Fonte: Produção do próprio autor.

Figura 23 - Curvas características $P \times V$ em função de S e T .



Fonte: Produção do próprio autor.

Através da Figura 22 e da Figura 23 fica claro que quanto maior o módulo da radiação solar, maior será a potência gerada pelo painel, concordando com (2.6), onde a corrente gerada I_{ph} é proporcional à radiação solar. A relação da potência com a temperatura não é a mesma, pois a potência decresce com o aumento da temperatura ambiente, e esta relação não é linear [15]. Neste trabalho, a influência da temperatura na tensão fornecida pelo painel é desconsiderada, logo, o efeito observado nas curvas de potência do painel em função da temperatura deverá ser diferenciado do apresentado por [15]. É importante observar que como foi desprezada essa variação da tensão do painel com a temperatura, o mesmo apresentou comportamentos um pouco discrepantes da realidade nas curvas em função da temperatura. Porém, esta diferença entre o modelo mais preciso e o modelo aqui utilizado não invalidam o método de MPPT que utiliza-se redes neurais artificiais (que serão melhor demonstradas nos capítulos 5 e 7), as quais se adaptariam rapidamente à um novo modelo utilizado, atingindo erros pequenos, como os que serão apresentados na seção 8.

4.1 ALGORITMOS DE MPPT

Serão aqui descritos de maneira breve o funcionamento de alguns dos algoritmos mais utilizados no rastreamento do ponto máximo de potência, segundo CHAPMAN.

4.1.1 Perturba e Observa (P&O) e *Hill Climbing*

Estas duas técnicas se baseiam num mesmo princípio para realização do MPPT, conforme Tabela 1.

Tabela 1 - Esquemático do algoritmo P&O / Hill Climbing.

ΔV	ΔP	MMPT
+	+	esquerda
+	-	direita
-	+	direita
-	-	esquerda

Fonte: Produção do próprio autor.

É primeiramente realizada uma variação (perturbação) na tensão do painel fotovoltaico, e então é observada a variação de potência. No caso da variação de tensão ser positiva, se a variação de potência é também positiva, o algoritmo então detecta que a operação atual do conversor se encontra à esquerda do ponto de máxima potência (MPP), e se a variação de potência é negativa, a operação atual do conversor está à direita do MPP. O contrário é visto no caso de uma perturbação de tensão negativa.

A diferença entre o P&O e o *Hill Climbing* é que o primeiro se utiliza de uma variação direta da variável de tensão para o MPPT enquanto que o segundo realiza uma variação do *duty cycle* do conversor para variar a potência de saída.

Este algoritmo apresenta problemas se houver uma variação brusca das condições climáticas, e também pode apresentar oscilações em torno do MPP. As variações bruscas no clima precisam ser devidamente detectadas e tratadas para que não ocorram problemas no rastreamento do MPP.

4.1.2 Condutância Incremental

O princípio de funcionamento desta técnica de MPPT é parecido com o citado acima. São definidas três condições baseadas nas derivadas da potência em relação à tensão.

A derivada da potência pode ser manipulada da seguinte forma: $\frac{dP}{dV} = \frac{d(V.I)}{dV} = I \frac{dV}{dV} + V \frac{dI}{dV} = I + V \frac{dI}{dV}$.

Porém, no MPP tem-se que $\frac{dP}{dV} = 0$, logo:

$$I + V \frac{dI}{dV} = 0 \rightarrow \frac{\Delta I}{\Delta V} = \frac{-I}{V} \quad (4.1)$$

Desta forma, a variação de potência em função da tensão pode ser analisada através do valor de condutância instantâneo do painel juntamente com sua variação.

Assim, facilmente tem-se que se $\frac{\Delta I}{\Delta V} > \frac{-I}{V}$, se está à esquerda do MPP e se $\frac{\Delta I}{\Delta V} < \frac{-I}{V}$, se está à direita do MPP. Se $\frac{\Delta I}{\Delta V} = \frac{-I}{V}$, a operação está exatamente no MPP.

Este método tem por vantagem o uso de passo variável para que seja encontrado o valor do MPP, levando a uma convergência mais rápida do método. Porém, como desvantagem, esta técnica tem problemas com múltiplos máximos e também com oscilações em torno do MPP.

4.1.3 Fração da Tensão de Circuito Aberto

Este método consiste em encontrar uma tensão de MPP fixa, onde esta é um valor proporcional à tensão de circuito aberto, segundo equação (4.2). A constante k_v depende do painel fotovoltaico utilizado e deve ser encontrada empiricamente.

$$V_{mpp} \approx k_v V_{oc} \quad (4.2)$$

Como este método se trata de apenas uma aproximação, não implica em um MPPT real, e como consequência as perdas deste tipo de método são maiores.

4.1.4 Fração da Corrente de Curto-Circuito

Este método consiste em encontrar uma corrente de MPP fixa, onde esta é um valor proporcional à corrente de curto-circuito, segundo equação (4.3). A constante k_i depende do painel fotovoltaico utilizado e deve ser encontrada empiricamente.

$$I_{mpp} \approx k_i I_{sc} \quad (4.3)$$

Como este método se trata de apenas uma aproximação, não implica em um MPPT real, e como consequência as perdas deste tipo de método são maiores novamente.

4.1.5 Controle por Lógica Fuzzy

O controle por Lógica Fuzzy é uma técnica de inteligência artificial baseada em funções de pertinência e variáveis linguísticas embasada nos comportamentos psicológicos. Na aplicação deste tipo de controle ao MPPT do painel, são definidas 5 pertinências: Negativo Grande (NG), Negativo Pequeno (NP), Zero (ZE), Positivo Pequeno (PP) e Positivo Grande (PG).

As entradas para o controlador Fuzzy são usualmente a derivada discreta da potência em relação à tensão, que é então definida como a variável erro, tal que $e(k) = \frac{P(k)-P(k-1)}{V(k)-V(k-1)}$, e a variação do erro $\Delta e = e(k) - e(k-1)$. Estes dois valores calculados então são traduzidos em termos de variáveis linguísticas, e estas poderão definir em qual das 5 pertinências se encontra o sistema no momento. O controlador, ao tomar conhecimento de uma das pertinências, gera então uma saída que frequentemente é definida como o *duty cycle* do conversor utilizado.

Este tipo de MPPT apresenta bons resultados mesmo em variações climáticas bruscas, porém tem como desvantagem a necessidade de “aprendizado” para cada painel especificamente.

4.1.6 Redes Neurais Artificiais

Também se trata de uma técnica de inteligência artificial, inspirada no comportamento das células nervosas biológicas. Um conjunto de neurônios artificiais simulam uma rede neural de organismos vivos. Os neurônios são basicamente unidades de processamento paralelas, que armazenam as informações do ambiente nas chamadas sinapses.

As variáveis de entrada para uma rede neural artificial a ser usada como MPPT variam bastante na literatura. As mais comumente usadas são a radiação solar S e a temperatura ambiente T , podendo também ser utilizados os valores de catálogo como V_{oc} , I_{sc} , V_{mpp} , I_{mpp} .

As redes neurais artificiais conseguem reproduzir um bom comportamento de saída na busca do MPP mesmo em grandes variações climáticas, porém, assim

como o controle baseado em Lógica Fuzzy, necessitam de um “aprendizado” específico de cada painel. Na seção 5 as redes neurais serão mais bem detalhadas.

4.1.7 Outras técnicas

Além das técnicas de MPPT citadas neste trabalho, existem outras como o RCC (*Ripple Correlation Control*), Varredura de Corrente, Controle realimentado por dP/dV ou dP/dI, Maximização da Tensão ou Corrente de Carga, entre outros. [16]

4.1.8 Discussão

Na escolha de um método de MPPT, diversos fatores devem ser levados em conta. Primeiramente deve-se analisar o tipo de aplicação envolvida, e os custos que se dispõe para realização. A forma como o MPPT será implementado, se o método possui ou não problemas com múltiplos máximos locais e até mesmo o número de sensores são variáveis que devem ser estudados antes de se decidir a escolha da técnica a ser utilizada. A Tabela 4-2 faz um comparativo simples entre as técnicas de MPPT aqui apresentadas [16].

Tabela 2 - Comparativo entre algumas técnicas de MPPT.

Técnica de MPPT	Depende do Arranjo FV?	MPPT verdadeiro ou falso?	Analógico ou Digital?	Velocidade de Convergência	Complexidade de Implementação	Sensores
<i>Hill Climbing</i> /P&O	Não	Sim	Ambos	Varia	Baixa	V,I
Cond. Incremental	Não	Sim	Digital	Varia	Média	V,I
Fração de Voc	Sim	Não	Ambos	Média	Baixa	V
Fração de Isc	Sim	Não	Ambos	Média	Média	I
Lógica Fuzzy	Sim	Sim	Digital	Rápida	Alta	Varia
Redes Neurais	Sim	Sim	Digital	Rápida	Alta	Varia

Fonte: Adaptado de CHAPMAN, ESRAM, 2007.

5 REDES NEURAIS ARTIFICIAIS

Nesta seção, serão discutidos os aspectos mais básicos de funcionamento de Inteligências Artificiais ou Inteligências Computacionais e também de Redes Neurais Artificiais. As Redes Neurais Artificiais serão utilizadas para a realização do rastreamento do máximo ponto de potência dos painéis solares neste trabalho, e serão demonstradas através de simulações computacionais.

5.1 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) estuda o conjunto de paradigmas que pretendem implementar comportamentos inteligentes que possam realizar tarefas cognitivas, nas quais os seres humanos são essencialmente melhores.

O que pode ser considerado um sistema inteligente ainda não é definido com clareza na literatura. Considera-se um programa de computador inteligente quando realiza uma tarefa, que se fosse feita por um ser humano, seria considerada inteligente. Sistemas complexos não devem ser confundidos com sistemas inteligentes. [17]

Uma das características de sistemas inteligentes é justamente a capacidade de aprender, armazenar conhecimento para resolver problemas, de se adaptar a um ambiente desconhecido ou a uma situação nova, se utilizar da experiência [17], [18].

Assim, pode-se dizer, em suma, que a IA é a reprodução do cérebro e sua capacidade de se auto organizar, ou seja, aprender, e utilizar sua experiência adquirida. Dois dos sistemas inteligentes muito conhecidos são a Lógica Fuzzy, que tenta simular a psicologia humana, e as Redes Neurais Artificiais (RNA), que buscam reproduzir computacionalmente a fisiologia humana [17].

5.2 CARACTERÍSTICAS DAS REDES NEURAIS

O cérebro humano pode ser entendido como uma máquina de processamento altamente complexa, não-linear e paralela. Ele tem a capacidade de organizar suas unidades de processamento, os neurônios, de forma a realizar atividades como a de guardar registros na memória, reconhecer padrões, traduzir e entender línguas, entre outras, de maneira muito rápida e com um gasto de energia muito menor por operação realizada do que o mais avançado dos computadores. Não é atoa que os seres humanos conseguem realizar tarefas como o processamento de imagens e tratamento de dados em frações de segundo, tornando o reconhecimento do rosto de um amigo, p.e., uma tarefa extremamente simples, mas que pode ser dispendiosa mesmo para o melhor dos computadores atuais [18].

Uma Rede Neural é justamente a conexão de diversas unidades de processamento paralelas (os neurônios) que realizam uma auto-organização ou mapeamento de entradas e saídas, sendo esta organização a experiência acumulada da mesma, ou seja, o conhecimento. Assim, informações sobre o ambiente podem ser armazenadas em uma rede neural através do aprendizado e posteriormente usadas para novas tarefas.

Podem ser resumidas as seguintes características das redes neurais:

- Capacidade de aprendizado: dados um conjunto de entradas e saídas, a rede neural é capaz de realizar um mapeamento deste conjunto.
- Aprendizagem por experiência: o ajuste dos dados aprendidos é realizado através do reconhecimento de padrões inerentes do comportamento do meio.
- Habilidade de generalização: capacidade de estimar saídas mesmo para entradas desconhecidas após o conhecimento do meio em questão.
- Organização de dados: uma rede neural é capaz de distinguir e separar dados com características semelhantes baseando-se no seu conhecimento.
- Tolerância à falhas: outros neurônios podem assumir a função daqueles que falharam no meio do processo, devido ao grande número de unidades.


- Armazenamento distribuído: a informação fica espalhada por toda rede neural.

Além destas seis características, a não-linearidade é outra propriedade muito importante das redes neurais, particularmente se o mecanismo físico responsável pela geração do sinal de entrada é também não linear [18].

5.3 O NEURÔNIO BIOLÓGICO

Os neurônios são as unidades elementares de processamento do cérebro, e tem por função conduzir ou inibir os sinais elétricos para as diferentes áreas do nosso corpo dependendo das suas condições. São divididos em dendritos, corpo celular e axônio, como ilustrado na Figura 24.


Figura 24 - Ilustrativo de um neurônio biológico.



Fonte: Hermano, 2009.

Os dendritos são os responsáveis por captar as respostas vindas de outros neurônios. Os sinais então captados pelos dendritos são processados dentro do corpo celular. Este decide então se será gerado um sinal de saída ou não. Caso seja decidido pela geração de um sinal de saída, o corpo celular gera um potencial de ativação (Figura 25), que fará com que o axônio conduza um impulso elétrico para os neurônios seguintes.

Figura 25 - Forma de onda do potencial de ativação.



Fonte: SILVA, SPATTI, FLAUZINO, 2010.

É interessante notar que não ocorre o contato físico entre os neurônios durante a transmissão dos sinais. Elementos chamados neurotransmissores são responsáveis por ponderar a transmissão dos impulsos elétricos de um neurônio para outro. O espaço existente entre o neurônio transmissor e o receptor é chamado de sinapse, e está representado na Figura 26.

Figura 26 - Sinapse de um neurônio biológico.



Fonte: ABCV, 2010.

É esta ponderação sináptica que fará com que o sinal elétrico a ser passado de um neurônio a outro tenha a devida amplitude julgada necessária pelo conhecimento adquirido anteriormente.

5.4 O NEURÔNIO ARTIFICIAL


No meio científico, verificou-se que para representar uma ferramenta inteligente seria necessário criar um sistema análogo ao cérebro humano, ou seja, um sistema composto por vários neurônios interligados, dando-se origem as RNAs. Partindo-se do modelo biológico de um neurônio, foram propostas diversas topologias de redes neurais, com funções de classificação, identificação e caracterização de sistemas. [19] O Neurônio Artificial é um modelo muito simplificado que tenta reproduzir o neurônio humano, inspirado na análise da geração e propagação dos impulsos elétricos no sistema nervoso.

Os neurônios artificiais utilizados nos modelos de Redes Neurais Artificiais são não lineares, fornecem saídas tipicamente contínuas, e realizam funções simples, como coletar os sinais existentes em suas entradas, processar estes sinais ponderando as entradas e produzindo saídas como resultado da função da soma das entradas ponderadas como argumento.

Em 1943, McCulloch & Pitts introduziu um dos primeiros modelos de neurônios, que ainda é um dos modelos mais utilizados nos dias hoje, e que engloba perfeitamente as características básicas de uma rede neural biológica [17].

Três são os elementos que compõe o neurônio artificial: o conjunto de sinapses, o combinador linear ou somador e a função de ativação. Na Figura 27 é apresentado o modelo não-linear de um neurônio artificial.

Figura 27 - Representação de um neurônio artificial.



Fonte: SILVA, SPATTI, FLAUZINO, 2010.


Os sinais de entrada são representados pelo vetor $X = [x_1^k \ x_2^k \ \dots \ x_n^k]$. Estes sinais serão ponderados pelo conjunto de pesos sinápticos $W = [w_1 \ w_2 \ \dots \ w_n]$, de tal forma que na entrada do combinador linear tem-se $w_1 x_1^k, w_2 x_2^k, \dots, w_n x_n^k$, ou seja, os pesos sinápticos irão quantificar o quão relevante é cada entrada.

Os sinais ponderados chegam até o combinador linear, que fará a soma ponderada de tal forma que $u_k = w_1 x_1^k + w_2 x_2^k + \dots + w_n x_n^k + b_k$. O termo b_k adicionado no modelo é o bias ou limiar de ativação, e tem a simples função de transladar o resultado do potencial de ativação u_k para especificar qual o patamar adequado de ativação de um neurônio no caso de uma função de ativação degrau, por exemplo, que será vista adiante. O potencial de ativação u_k também pode ser conhecido como campo local induzido [18].

A saída do neurônio é o termo y_k , onde $y_k = g(u_k)$. A função $g(\cdot)$ é a função de ativação do neurônio, que pode tomar diferentes formas, sendo as mais típicas mostradas a seguir.


5.5 FUNÇÕES DE ATIVAÇÃO

A função de ativação define a saída do neurônio em termos do potencial de ativação. Os principais tipos de função de ativação são [17]:

Figura 28 - Função Degrau.


Fonte: SILVA, SPATTI, FLAUZINO, 2010.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (5.1)$$

Figura 29 - Função Sinal.

Fonte: SILVA, SPATTI, FLAUZINO, 2010.


$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (5.2)$$

Figura 30 - Função Linear.

Fonte: SILVA, SPATTI, FLAUZINO, 2010.

$$g(u) = u \quad (5.3)$$


Figura 31 - Função Sigmóide.



Fonte: SILVA, SPATTI, FLAUZINO, 2010.

$$g(u) = \frac{1}{1+e^{-\beta u}} \quad (5.4)$$


Figura 32 - Função Tangente Hiperbólica.



Fonte: SILVA, SPATTI, FLAUZINO, 2010.

$$g(u) = \frac{1-e^{-\beta u}}{1+e^{-\beta u}} \quad (5.5)$$

Figura 33 - Função Gaussiana.



Fonte: SILVA, SPATTI, FLAUZINO, 2010.

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (5.6)$$

5.6 ARQUITETURAS DE REDE

As redes fundamentalmente são constituídas de uma camada de entrada, uma camada de saída, e podem ou não ter uma ou mais camadas ocultas, também conhecidas por camadas intermediárias.

- Camada de entrada: é aquela que recebe os sinais vindos do ambiente para que sejam introduzidos dentro da rede. No caso de redes que se utilizem de realimentação, uma ou mais saídas da rede podem servir como sinal de entrada. As entradas geralmente são normalizadas para facilitar as faixas de trabalho nas quais a função de ativação deve atuar. Esta camada não é constituída de neurônios.
- Camada oculta ou intermediária: camada composta de neurônios responsáveis por extrair e armazenar o conhecimento advindo do meio externo. Todo processamento do conhecimento da rede é geralmente feito nesta camada.
- Camada de saída: é onde se obtém todo o sinal processado pela rede, e também é constituída de neurônios.

As RNAs podem ter diferentes arquiteturas e topologias. A arquitetura de uma rede define, por exemplo, se está terá ou não o uso de realimentação, se será uma rede de camada simples ou múltipla, entre outros aspectos. Já a topologia da rede neural define o tipo de função de ativação utilizada, o número de neurônios em cada camada, ou o número de camadas ocultas no caso de uma rede de camadas múltiplas.

As principais arquiteturas de rede são as redes *feed-forward* (alimentação adiante) de camada simples, *feed-forward* de camadas múltiplas, redes recorrentes ou realimentadas e redes reticuladas.

Ao se criar a arquitetura e topologia de uma rede neural, espera-se que a rede escolhida seja sintética, isto é, tenha o mínimo de camadas e neurônios necessários a cumprir o desempenho desejado, com o objetivo de exigir o menor esforço computacional, principalmente para ser viável na aplicação em eletrônica de potência através de um DSP, por exemplo [20].

5.7 PROCESSOS DE APRENDIZADO

Para a utilização de técnicas de inteligência computacional, como as RNAs, nenhum conhecimento a priori das relações físicas entre as variáveis do sistema é necessário, sendo o único pré-requisito, a existência de uma base de dados histórica capaz de representar a dinâmica do processo em questão [21].

Um dos destaques mais relevantes das Redes Neurais Artificiais está na capacidade de aprender a partir da apresentação de amostras que exprimem o comportamento do sistema a ser analisado. O aprendizado é a primeira etapa a ser realizada num processo de utilização de uma rede neural. Após o aprendizado, a rede será capaz de produzir uma saída próxima daquela esperada (desejada) a partir de quaisquer sinais inseridos em suas entradas [17].

Na fase de aprendizagem, a rede extrai as informações relevantes do ambiente, criando assim uma representação própria do problema. Esta etapa é fundamentada num processo iterativo onde seus parâmetros, os pesos sinápticos, são ajustados continuamente até que, ao final, apresentarão o conhecimento adquirido pela rede ao longo do processo de treinamento [24].

O conjunto de passos ordenados efetuados para o treinamento da rede é denominado algoritmo de aprendizagem.

Em geral, o conjunto de amostras da rede é dividido em dois subconjuntos. Um deles é o conjunto de treinamento, que compõe os dados que serão efetivamente usados para treinar a rede. O outro é o conjunto de dados de validação, usados para validar o modelo da rede neural, ou seja, constatar que esta é capaz de oferecer resultados próximos dos esperados e com boa capacidade de generalização [17].


Serão apresentados alguns dos tipos de processos de aprendizagem mais comuns.

5.7.1 Aprendizado Supervisionado

No aprendizado supervisionado, o conjunto de amostras de treinamento deve disponibilizar um par composto pelo vetor de entrada e seu respectivo vetor de saída desejada.

No funcionamento deste método, em suma, a RNA poderá iniciar seu vetor de pesos hipoteticamente com quaisquer valores, que irão ponderar as entradas e resultar num vetor inicial de saída qualquer. Tendo agora os valores de saída da rede e o respectivo valor de saída desejada associada à amostra de entrada, a RNA pode então calcular o erro, e saber o quão longe está de sua referência de saída. É através deste erro que os pesos sinápticos vão sendo ajustados. Este tipo de aprendizado pode ser comparado a uma malha de controle fechada, como ilustrado na Figura 34.

Figura 34 - Malha de uma RNA treinada por aprendizado supervisionado.



Fonte: Adaptado de BRAGA, LUDEMIR, CARVALHO, 2000.

Pode-se facilitar este entendimento em termos de um exemplo. Imagine uma criança que inicie um treino de basquete, e queria começar treinando arremessos parados à cesta. Pode-se considerar os valores de entrada como sendo o ângulo de inclinação do arremesso e a força, que serão ponderados pelos pesos sinápticos. A criança inicialmente irá errar os arremessos, jogando a bola com mais força do que deveria (peso sináptico correspondente à força está maior do que deveria, p.e.) ou

então tacando a bola abaixo do nível da cesta (indicando que o ângulo do arremesso deveria ser maior, p.e.). Conforme a criança avança no processo de treinamento, os erros tendem a ficar cada vez menores, até que chegará o momento em que ela saberá com precisão razoável qual deve ser a ponderação da força e do ângulo de arremesso para que este seja certo. A criança pode ser considerada finalmente treinada para o processo.

Este processo pode ser matematicamente traduzido conforme se segue: Considerando o vetor de entrada $X = [F \ \theta]$ e a saída desejada como sendo y_d , que é a posição da bola ao longo do eixo transversal a cesta de basquete. O vetor de pesos da rede é então definido por $W(k) = [w_1(k) \ w_2(k)]^T$ e o bias será definido em zero por conviência. Assim, o potencial de ativação será $u(k) = X \times W(k) = Fw_1(k) + \theta w_2(k)$. Supondo que a função de ativação do neurônio é uma função do tipo linear, então a saída do neurônio é $y(k) = u(k) = Fw_1(k) + \theta w_2(k)$. A partir da saída calculada da rede, tem-se então que o erro é $e(k) = y_d - y$. Por fim, o ajuste dos pesos é executado de forma que:

$$w_i(k + 1) = w_i(k) + \eta \cdot e(k) \cdot x_i(k) \quad (5.7)$$

onde η é uma constante chamada de taxa de aprendizado e que é utilizada em geral para acelerar ou controlar a convergência numérica do método.


Este ajuste de pesos geralmente é feito de forma a atender a minimização de uma função de custos, resultando em um erro quadrático médio menor que uma precisão pré-definida.

5.7.2 Aprendizado Não-Supervisionado

Neste tipo de aprendizado, não há conhecimento de quão distante a resposta da RNA está da saída desejada. Somente estão disponíveis as variáveis de entrada no conjunto de amostras de treinamento. Muitos dos sistemas biológicos dos seres humanos são treinados a partir do aprendizado não-supervisionado, como por exemplo os estágios iniciais da visão e da audição [24].

A fixação do conhecimento nesse tipo de treinamento não é tão intuitiva quanto o do treinamento supervisionado. A partir do momento que a RNA estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se a habilidade de formar padrões internos para decifrar comportamentos da entrada e criar novos agrupamentos automaticamente. Sendo assim, este tipo de treinamento só é realizável se houver uma redundância dos dados de entrada. Este tipo de aprendizado pode ser encarado como sendo uma malha de controle aberta. (Figura 35)

Figura 35 - Malha de uma RNA treinada por aprendizado não-supervisionado.



Fonte: Adaptado de BRAGA, LUDEMIR, CARVALHO, 2000.

5.7.3 Aprendizado por Reforço

O aprendizado por reforço pode ser facilmente confundido com o aprendizado supervisionado. No aprendizado por reforço, assim como no aprendizado supervisionado, existe uma informação do ambiente para comparação da saída, mas esta, diferentemente do aprendizado supervisionado, é só um sinal de reforço. Isso indica que o reforço diz apenas se o alvo desejado foi atingido ou não, não informando o quão longe se está da resposta esperada. Neste caso, o conjunto de amostras de treinamento não conta com o vetor de saídas desejadas. A único sinal a ser comparado com o sinal de saída é o próprio sinal de reforço informado a rede, que pode dizer, por exemplo, se o treinamento terminou ou não.

5.8 APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS COMO TÉCNICA DE MPPT EM PAINÉIS FOTOVOLTAICOS

Como citado anteriormente na seção 4.1.6, as Redes Neurais Artificiais podem ser utilizadas no rastreamento do máximo ponto de potência de painéis solares. Escolhendo-se variáveis de entrada como temperatura, radiação solar, corrente de saída do painel, tensão de saída do painel, dentre outras, e fixando como saída da RNA a tensão ou corrente na saída do painel pode-se fazer com que a RNA aprenda o comportamento da tensão, corrente ou potência de saída do painel em função das variáveis de entrada. Assim as RNAs podem ser utilizadas como ferramentas de MPPT para painéis fotovoltaicos.

5.9 HIPÓTESES

A seguir serão listadas algumas hipóteses referentes a este trabalho:

- As simulações serão realizadas no *software* MATLAB.
- As Redes Neurais Artificiais pode ser utilizadas como método de MPPT obtendo-se uma convergência acelerada do método.
- A utilização de RNAs no processo de MPPT pode acarretar em menores oscilações na saída do conversor [22].
- O aprendizado da rede deverá ser realizado de forma supervisionada.
- A melhor arquitetura e topologia da RNA utilizada no MPPT deverá ser escolhida empiricamente.
- A escolha da função de ativação da RNA também se dará pelo método empírico.
- Os dados escolhidos da base de dados climática estarão entre às 8 e 20 horas, obtendo assim uma boa quantidade de amostras de temperatura e radiação que efetivamente têm representatividade, visando atender os horários com maior insolação ao longo do dia, e desprezando os valores de radiação próximos de zero.

- Ter vários valores de radiação ou temperatura semelhantes não agregam conhecimento às redes neurais artificiais.
- Visando atender uma maior variedade nos dados climáticos, serão escolhidos dados ao longo de quatro estações do ano, quando os grupos de amostras forem relativamente pequenos, para que possa avaliar uma maior representatividade dos dados climáticos e dos resultados de potência do painel fotovoltaico.
- As RNAs possuem rápido tempo para obtenção do máximo ponto de potência, uma vez que estas já estejam treinadas.

6 OBTENÇÃO DOS PARÂMETROS DO PAINÉL FOTOVOLTAICO

A obtenção dos parâmetros do painel fotovoltaico pode ser feita de diversas formas. Alguns deles podem ser obtidos através do método analítico e outros, devem ser calculados a partir de métodos numéricos ou adquiridos experimentalmente.

6.1 DADOS DE CATÁLOGO DO PAINEL FOTOVOLTAICO UTILIZADO

O Sunmodule® SW 130 Poly/R6A, fabricado pela SolarWorld [36], é um painel fotovoltaico composto por células de silício policristalino. O mesmo é ilustrado na Figura 36.

Figura 36 – Ilustração do painel fotovoltaico SW 130 Poly/R6A.



Fonte: SolarWorld Solar Panels.

Os dados de catálogo deste painel estão presentes na Tabela 3, todos obtidos em STC.

Tabela 3 - Dados de catálogo SW 130 Poly/R6A.


Dados SW 130 Poly R6A	
P_{mpp}	130 Wp
V_{oc}	21,9 V
V_{mpp}	17,7 V
I_{sc}	7,65 A
I_{mpp}	7,38 A
N_s	36
K_{ti}	0,034 %/K

Fonte: SolarWorld Solar Panels.

6.2 CÁLCULO DOS PARÂMETROS DO PAINEL FOTOVOLTAICO

Tendo em mãos os dados de catálogo do painel fotovoltaico, deve-se então através dos mesmos, alcançar os parâmetros restantes. No caso do Painel SW 130 Poly/R6A, os parâmetros R_s , R_p , I_{so} , A ainda devem ser determinados. Primeiramente devem ser calculados valores aproximados de I_{so} e A , para que então uma função custo possa ser montada para a posterior utilização de Algoritmos Genéticos (*Genetic Algorithms* - GA), para a determinação de R_s e R_p , que serão brevemente discutidos na seção 6.2.2, mas não serão detalhados neste trabalho, pois a GA foi utilizada apenas como ferramenta através da função já existente no MATLAB. Tendo finalmente os valores de R_p e R_s determinados a partir de GA, finalmente podem ser determinados os valores finais de I_{so} e A finais. Na Figura 37, apresenta-se o fluxograma que descreve a obtenção dos parâmetros do painel solar.

Figura 37 - Fluxograma de obtenção dos parâmetros do painel solar



Fonte: Produção do próprio autor.

6.2.1 Aproximação do Fator de Idealidade do Diodo e da sua Corrente de Saturação na Temperatura de Referência

Como pode ser visto em (3.1) e (3.6), a constante de idealidade do diodo e sua corrente de saturação reversa na temperatura de referência são dependentes do valor de R_p . Desta forma, deve-se inicialmente realizar a aproximação onde $R_p \rightarrow \infty$, que é uma aproximação condizente com a realidade do painel, e que permite assim eliminar a dependência das equações descritas anteriormente com R_p , transformando as equações (3.1) e (3.6) nas seguintes equações:

$$I_{So} = \frac{I_{sc}}{e^{\frac{V_{oc}}{AV_T}} - 1} \quad (7.1)$$

$$A = \frac{V_{mpp} - V_{oc}}{V_T \ln\left(\frac{I_{sc} - I_{mpp}}{I_{sc}}\right)} \quad (7.2)$$

Deste modo, obtém-se os valores aproximados de $I_{so} = 2,046 \times 10^{-7}$ A e $A = 1,3579$.

6.2.2 Algoritmos genéticos para determinação das resistências

Diferentemente de [9], onde se utiliza do método de newton-raphson para a determinação numérica dos valores das resistências do modelo, as resistências R_p e R_s serão obtidas através de algoritmos genéticos no MATLAB.

Algoritmos Genéticos são baseados no comportamento biológico, onde uma população numérica é aleatoriamente inicializada e utilizada no cálculo de uma função de custo, que necessita ser minimizada. Conforme a população se desenvolve, seus indivíduos genéticos vão convergindo para a solução final que minimiza a função de custo dada.

Utilizando a equação (2.2) e já substituindo a equação (2.3) em I_D , facilmente obtém-se (7.3):

$$I = I_{ph} - I_s(e^{\frac{1}{T_r}(\frac{q}{Ak})(V+R_s I)} - 1) - \frac{V+R_s I}{R_p} \quad (7.3)$$

Tendo então os valores de catálogo da Tabela 3 e a aproximação dos parâmetros dada por (7.1) e (7.2), pode-se manipular (7.3) para a condição de máxima potência no STC, onde $I = I_{mpp}$, $V = V_{mpp}$, $I_s = I_{so}$, o que resulta em (7.4):

$$I_{mpp} = I_{ph} - I_{so}(e^{\frac{1}{T_r}(\frac{q}{Ak})(V_{mpp}+R_s I_{mpp})} - 1) - \frac{V_{mpp}+R_s I_{mpp}}{R_p} \quad (7.4)$$

Finalmente, multiplicando (7.4) por V_{mpp} , deve-se atingir como resultado P_{mpp} , que é o valor de potência máxima fornecida no catálogo do fabricante. Assim, a função J custo a ser minimizada é formada através de (7.4), dependente de R_s e R_p , que precisam ser encontrados, conforme mostrado em (7.5):

$$J(R_s, R_p) = P_{mpp} - V_{mpp} \cdot I_{mpp}(R_s, R_p) \quad (7.5)$$

Assim, utilizando a função “ga” do MATLAB, obtém-se facilmente através de Algoritmos Genéticos os valores das resistências do modelo. Como este método é um método que inicia com variáveis aleatórias, seu resultado será diferente a cada execução. Sendo assim, depois de obtidos os seguintes valores de $R_s = 3,79 \times 10^{-5} \Omega$ e $R_p = 7,42 \times 10^7 \Omega$, e sabendo-se que estes valores são condizentes com a realidade do painel fotovoltaico, onde a resistência série deve ser bastante pequena e a resistência paralela deve ser bastante grande, os mesmos foram fixados e serão utilizados até o final do presente trabalho.

6.2.3 Cálculo das Constantes do Diodo

A constante de idealidade do diodo A e a corrente de saturação do diodo na condição de referência I_{so} agora podem ser calculadas com mais exatidão, uma vez que os valores de resistência do circuito equivalente já são conhecidos. Aplicando os valores de catálogo do painel e também os valores de resistência nas equações (3.1) e (3.6), calcula-se então os parâmetros restantes do painel fotovoltaico. Os resultados dos quatro parâmetros a serem determinados são mostrados na Tabela 4

Tabela 4 - Parâmetros do painel fotovoltaico obtidos numericamente e analiticamente.

Parâmetros obtidos do painel	
Rs	$3,79 \times 10^{-5} \Omega$
Rp	$7,42 \times 10^7 \Omega$
A	1,3577
Iso	2.0422×10^{-7}

Fonte: produção do próprio autor.

7 CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL

A escolha da arquitetura da RNA, de suas topologias e também da árvore de amostragem utilizada para o seu treinamento foram definidas basicamente de forma empírica, com exceção da arquitetura *Multi-Layer Perceptron* (MLP), que foi escolhida com base na literatura e por ser amplamente usada em soluções como a apresentada neste trabalho.

7.1 MULTI-LAYER PERCEPTRON E A TOPOLOGIA UTILIZADA


As redes MLP são extremamente conhecidas na literatura, e apresentam resultados bem satisfatórios para diversos problemas. São constituídas basicamente de uma camada de entrada, geralmente formada pelas entradas, uma camada intermediária que irá conter o conhecimento adquirido do ambiente externo e uma camada de saída, que em geral é composta por apenas um neurônio. Contendo apenas uma camada de neurônios oculta, esta rede é capaz de reproduzir qualquer função contínua. Esta arquitetura foi escolhida para a implementação do MPPT.

Com relação a sua topologia, foi fixada a camada de entrada como sendo composta apenas pela temperatura e pela radiação solar incidente. Poderiam ainda ser utilizados os próprios valores de tensão e corrente de saída do painel fotovoltaico, bastando para tal a imposição destas duas variáveis como entradas, e obtendo as saídas desejadas também em função destas duas variáveis. A saída é composta por um único neurônio, responsável por fornecer o valor de tensão desejado na saída do painel, o qual deve ser imposto pelo conversor a ser utilizado. Quanto às camadas ocultas, apenas uma é suficiente, uma vez que esta é a quantidade mínima para que qualquer função contínua possa ser reproduzida, e utilizar-se de uma quantidade maior de camadas ocultas resultaria em uma complexidade maior e desnecessária, tornando assim a RNA não sintética. Uma RNA sintética é aquela que consegue exprimir todo o conhecimento do ambiente externo utilizando o menor número de neurônios e camadas intermediárias. A

quantidade de neurônios na camada oculta será determinada empiricamente. Na Figura 38 pode ser visualizar a RNA de maneira geral, contendo suas três camadas: a entrada composta pelas variáveis climáticas, o número de neurônios na camada oculta a ser descoberto, e um neurônio na camada de saída. As funções de ativação a serem analisadas são a função sigmoide e a função tangente hiperbólica.

Para definir as melhores estruturas de RNA, foram analisados os critérios de tempo de treinamento da RNA, número de épocas para atingir a convergência, e o erro médio quadrático final associado às mesmas.

Figura 38 – Representação da RNA MLP construída.



Fonte: Produção do próprio autor.

7.2 A BASE DE DADOS DE TREINAMENTO

Para garantir o funcionamento do MPPT através do uso de RNAs, é fundamental que seja escolhida uma base de dados íntegra, com dados confiáveis, e que a partir desta sejam selecionados os dados de maneira criteriosa, de forma que os estes possam agregar conhecimento para a RNA.


A base de dados climáticos do Sistema de Organização Nacional de Dados Ambientais (SONDA), provida pelo Instituto Nacional de Pesquisas Espaciais (INPE) [23] se mostrou uma excelente fonte. Os dados climatológicos utilizados foram os da Estação de Joinville. Estes dados passam por uma validação, e por isso tem uma alta confiabilidade.

Para a seleção dos dados climáticos obtidos, foi feita uma análise com base nos que poderiam agregar maior conhecimento para a RNA. Em outras palavras, é melhor que haja dados climáticos espalhados ao longo das quatro estações do ano do que dados condensados em apenas uma, por exemplo. Sendo assim, todos os dados foram classificados em cinco diferentes tamanhos de amostras climáticas. O primeiro grupo de amostras é composto pelo primeiro dia do mês de cada estação do ano (dos meses de Janeiro, Abril, Julho e Outubro do ano de 2009). Cada dia avaliado, contém cerca de 13 amostras de temperatura e radiação solar, com amostragens realizadas de hora em hora das 8 às 20 horas (a base de dados pode ter perdido algumas amostras durante as medições ou estas não passaram no teste de validação). O segundo grupo de amostras contém dois dias de amostra de cada um dos meses já escolhidos acima (dias primeiro e dezesseis de cada mês). O terceiro grupo de amostras contém amostras de todos os dias dos meses de Janeiro, Abril, Julho e Outubro de 2009. O quarto grupo de amostras contém todas as amostras climáticas disponíveis ao longo do ano de 2009. E o último grupo possui amostras de todo o ano de 2009 e 2011. Para a validação dos dados, foram escolhidos os dados climáticos do primeiro dia de cada mês do ano de 2012 (totalizando 12 dias ao longo do ano).

Com esta seleção de dados, foi feita então uma simulação do painel fotovoltaico para cada amostra de radiação e temperatura. Nesta simulação, são gerados através dos valores de temperatura e radiação solar e também dos parâmetros do painel solar, as curvas de corrente por tensão e de potência por tensão do painel solar. Sendo assim, é possível obter o valor de máximo da curva de potência do painel solar para diferentes valores de radiação e temperatura, ou seja, é possível obter o valor da potência no MPP, além do seu respectivo valor e tensão e consequentemente o seu valor de corrente. O processo de obtenção dos valores de tensão a serem usados na RNA é descrito na Figura 39. Logo, foram realizadas inúmeras simulações de forma iterativa, a fim de conseguir os valores de tensão no

MPP para o painel solar dado, tanto para a realização do treinamento da RNA quanto para sua validação. Em suma, tem-se a partir deste ponto um par de entradas-saídas, onde para cada valor de radiação solar e temperatura do ambiente, sabe-se qual deve ser o valor de tensão que levará o painel à extração de sua máxima potência.

Figura 39 – Fluxograma do algoritmo de obtenção dos valores de V_{mpp} para o uso nas RNAs.




Fonte: Produção do próprio autor.

7.3 A FASE DE TREINAMENTO

Tendo em mãos os pares de entrada-saída, compostos pelos dados climáticos de radiação e temperatura e pela saída de tensão desejada, pode-se então iniciar o treinamento da RNA. Foram feitas 48 simulações de MPPT por RNA através da variação do número de neurônios da camada oculta, do número de amostras de treinamento utilizadas e da função de ativação selecionada, conforme ilustrado na árvore de amostragem da Figura 40.


Figura 40 – Árvore de amostragem para simulações.



Fonte: produção do próprio autor.


Na Figura 41 apresenta-se o fluxograma que demonstra o funcionamento da RNA na fase de treinamento. A fase de validação está representada pelo fluxograma da Figura 42.

Figura 41 - Fluxograma do algoritmo de treinamento da RNA.



Fonte: Produção do próprio autor.

Figura 42 - Fluxograma do algoritmo de validação da RNA.




Fonte: Produção do próprio autor.

8 RESULTADOS

A obtenção dos resultados foi obtida através de três fatores a serem analisados: o número “k” de épocas necessárias para a convergência durante a fase de treinamento (a convergência do método foi fixada em 1×10^{-3}), o tempo de execução do algoritmo na fase de treinamento e por fim o erro médio quadrático final (mse), obtido através da fase de validação. Através do mse, também será realizada a validação da RNA como método de MPPT. Todos estes fatores foram avaliados para cada grupo de amostras, com a variação do número de neurônios na camada intermediária e diferentes tamanhos de amostras de treinamento, com diferentes funções de ativação.


Na Figura 43, estão presentes os resultados do número de épocas para convergência utilizando a função de ativação sigmóide. Na Figura 44 podem ser avaliados os mesmos fatores em uma RNA com função de ativação tangente hiperbólica.

Figura 43 - Número de épocas de treinamento utilizando função sigmóide.



Fonte: produção do próprio autor.


Figura 44 - Número de épocas de treinamento utilizando função tangente hiperbólica.



Fonte: Produção do próprio autor.


Na Figura 45, foi avaliado o tempo de convergência da fase de treinamento em função do número de amostras e do número de neurônios na camada intermediária, utilizando-se a função de ativação sigmóide, enquanto que na Figura 46, foi utilizada a tangente hiperbólica como função de ativação.

Figura 45 - Tempo de execução do algoritmo de treinamento utilizando função sigmóide.



Fonte: Produção do próprio autor.

Figura 46 - Tempo de execução do algoritmo de treinamento utilizando função tangente hiperbólica.



Fonte: Produção do próprio autor.

Por fim, o erro médio quadrático da fase de validação pode ser analisado. O erro médio quadrático é caracterizado pela soma dos erros quadráticos individuais de cada amostra de saída dividido pelo número de amostras, conforme (9.1):


$$mse = \sum_{s=1}^n \frac{(y^{(s)} - y_d^{(s)})^2}{n} \quad (9.1)$$

Sendo assim, quanto menor o mse, mais próxima a RNA estará do resultado desejado. É este valor que é analisado durante a fase de treinamento para indicar se a RNA está treinada. Após o treinamento, a base de dados climáticos do ano de 2012, que não havia sido usada durante o treinamento, foi usada para a validação da RNA. Assim, o mse avaliado será o da fase de validação.

A maior variação do mse se deu entre o número de amostras de treinamento utilizadas. O número de neurônios na camada oculta teve influência relevante somente durante a fase de treinamento para a avaliação da eficiência computacional da RNA, onde foram avaliados o número de épocas e o tempo de execução do algoritmo de treinamento. Sendo assim, foi feita uma média dos erros médios quadráticos com relação ao número de neurônios utilizados, gerando assim um novo índice, a média dos erros médios quadráticos (amse), que será utilizada nesta validação, dispensando uma análise do mse para cada neurônio, já que a variação


do mse entre neurônios é desprezível. Os resultados do amse para diferentes números de amostras de treinamento são mostrados na Figura 47 e na Figura 48, que têm por função de ativação a sigmóide e a tangente hiperbólica, respectivamente.

Figura 47 – Média dos erros médios quadráticos em função do número de amostras de treinamento utilizando função de ativação sigmóide.



Fonte: Produção do próprio autor.

Figura 48 - Média dos erros médios quadráticos em função do número de amostras de treinamento utilizando função de ativação tangente hiperbólica.



Fonte: Produção do próprio autor.

O grande destaque na utilização da RNA para a realização do rastreamento do máximo de potência é a sua agilidade na obtenção do máximo ponto de potência, quando tem-se a RNA já treinada. Outro fator importante é a facilidade de modificação da estrutura da RNA. Uma vez a RNA implementada em um microcontrolador ou sistema embarcado, basta a gravação de um novo software para que se altere toda a sua arquitetura, sem que haja necessariamente mudanças no hardware utilizado.

Através destes resultados, pode-se observar que a RNA consegue reproduzir as saídas desejadas com fidelidade, mesmo para entradas desconhecidas por ela. Os erros observados na fase de validação foram mínimos. Outro aspecto a ser levado em consideração é a tendência de crescimento do amse em função do número de amostras, que será comentado na conclusão.

CONCLUSÃO

Ao realizar as simulações de um painel fotovoltaico, observou-se primeiramente a dificuldade de possuir em mãos todos os parâmetros do mesmo. Assim sendo, o primeiro grande desafio deste trabalho foi encontrar todos os parâmetros do módulo solar em questão, de maneira analítica ou computacional, e isto pôde ser realizado utilizando-se como ferramenta os algoritmos genéticos. Através desta, pode-se chegar a valores teóricos muito bons, condizentes com a realidade, em que a resistência série do circuito equivalente se aproxima de zero e a resistência paralela é suficientemente grande. Apesar de serem bons resultados teóricos, estes não foram comparados a quaisquer resultados experimentais.

A análise de funcionamento da RNA também se mostrou trabalhosa, necessitando de várias simulações, pois seu funcionamento só pode ser avaliado de forma empírica. Nesta análise, verifica-se primeiramente a superioridade do uso da tangente hiperbólica como função de ativação, levando-se em conta os esforços computacionais necessários à etapa de treinamento. O uso da tangente hiperbólica levou a um número de épocas de treinamento menor e conseqüentemente a tempos de convergência do algoritmo muito menores. A única desvantagem observada em seu uso foi a média dos erros médios quadráticos, que apresentou valores ligeiramente maiores se comparados à função sigmóide, mas que ainda assim são pequenos o suficiente para que possa ser justificada a escolha da função tangente hiperbólica como melhor opção de função de ativação para o propósito deste trabalho.

O número de neurônios da camada oculta quase não exerce influência sobre o número de épocas necessárias para convergência, porém influencia no tempo de execução do algoritmo de treinamento, afinal, o aumento do número de neurônios acarreta em uma maior complexidade do algoritmo, ao passo que o uso de poucos neurônios pode dificultar o aprendizado da RNA, por esta conter um número reduzido de pesos que fixarão o seu conhecimento.

Por fim, o número de amostras de treinamento utilizadas foi fundamental tanto para a fase de treinamento quanto nos resultados obtidos pela RNA. É possível

visualizar que utilizando um número pequeno de amostras de treinamento, a RNA necessita de maior esforço computacional para atingir a convergência durante o treinamento, mas que utilizando-se um número muito grande de amostras, pode-se esperar também maiores esforços computacionais. Sendo assim, existe um número ótimo de quantidade de amostras a serem utilizadas durante o treinamento, que não deve ser nem tão pequeno e nem tão grande, e que foi avaliado em 97 neste trabalho. A média do erro médio quadrático apresentou comportamento peculiar em função do número de amostras de treinamento. Observa-se que há uma tendência de crescimento do amse conforme o aumento do número de amostras de treinamento, a partir da utilização de 97 amostras. Este fenômeno é provavelmente resultado de um sobretreinamento, que é a utilização de um número exagerado de amostras, que pode acarretar em resultados indesejados como os mostrados na seção 8.

REFERÊNCIAS

- [1] ONU (Estados Unidos). **WORLD URBANIZATION PROSPECTS**. Review. Disponível em: <<http://www.un.org/en/development/index.shtml/desa/index.html>>. Acesso em: 18 out. 2012.
- [2] EPE. **BALANÇO ENERGÉTICO NACIONAL 2012**. BEN. Disponível em: <https://ben.epe.gov.br/downloads/Resultados_Pre_BEN_2012.pdf>. Acesso em: 18 out. 2012.
- [3] QUEIROZ, Leonardo Mendonça Oliveira de. **ESTIMAÇÃO E ANÁLISE DAS PERDAS TÉCNICAS NA DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**. 2010. 155 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 2010. Cap. 1. Disponível em: <http://www.aneel.gov.br/biblioteca/trabalhos/trabalhos/tese_leonardo%20queiroz.pdf>. Acesso em: 18 out. 2012.
- [4] COELHO, Roberto Francisco. **ESTUDO DOS CONVERSORES BUCK E BOOST APLICADOS AO RASTREAMENTO DE MÁXIMA POTÊNCIA DE SISTEMAS SOLARES FOTOVOLTAICOS**. 2008. 176 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal De Santa Catarina, Florianópolis, 2008. Cap. 1.
- [5] PEREIRA, Dante Victor Shimoda. **CONVERSOR CC-CC BOOST COM MPPT ALIMENTADO POR PAINÉIS FOTOVOLTAICOS PARA APLICAÇÃO EM GERAÇÃO DISTRIBUIDA**. 2010. 107 f. Monografia (Graduação) - Curso de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2010. Cap. 1.
- [6] CRESEB. **TUTORIAL DE ENERGIA SOLAR FOTOVOLTAICA**. Disponível em: <http://www.cresesb.cepel.br/content.php?cid=tutorial_solar>. Acesso em: 18 out. 2012.
- [7] CASARO, Marcio Mendes. **INVERSOR TRIFÁSICO DE DOIS ESTÁGIOS MODIFICADO APLICADO NO PROCESSAMENTO DA ENERGIA SOLAR FOTOVOLTAICA EM SISTEMAS CONECTADOS À REDE ELÉTRICA**. 2009. 188 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal De Santa Catarina, Florianópolis, 2009. Cap. 1.
- [8] MARTINS, Denizar Cruz; COELHO, Roberto Francisco; SANTOS, Walbermark Marques Dos. **TÉCNICAS DE RASTREAMENTO DE MÁXIMA POTÊNCIA PARA SISTEMAS FOTOVOLTAICOS: REVISÃO E NOVAS PROPOSTAS**. In:

CONGRESSO BRASILEIRO DE ELETRÔNICA DE POTÊNCIA, 11., 2011, Natal. SHORT COURSE 3. Natal, 2011.

- [9] VILLALVA, Marcelo Gradella; GAZOLI, Jonas Rafael; RUPPERT FILHO, Ernesto. **COMPREHENSIVE APPROACH TO MODELING AND SIMULATION OF PHOTOVOLTAIC ARRAYS**. IEEE Transactions On Power Electronics, v. 24, n. 05, p.1200-1204, 01 maio 2009.
- [10] CHUCO, Braulio. **OTIMIZAÇÃO DA POTÊNCIA DE OPERAÇÃO EM SISTEMA ISOLADO FOTOVOLTAICO USANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**. 2007. 97 f. Dissertação (Mestrado) - Universidade Federal Do Mato Grosso Do Sul, Campo Grande, 2007. Cap. 1.
- [11] POWERSIM INC. **PSIM User's Guide**, 2010.
- [12] CAMUS, Cristina; EUSÉBIO, Eduardo. **GESTÃO DE ENERGIA: ENERGIA SOLAR**. ISEL. Disponível em: <<http://pwp.net.ipl.pt/deea.isel/ccamus/Doc/energias5.pdf>>. Acesso em: 15 set. 2012.
- [13] VALENTE, Miguel Ângelo Silveiro. **Caracterização Automática de um Painei Fotovoltaico**. 2011. 69 f. Dissertação (Mestrado) - Universidade Nova De Lisboa, Lisboa, 2011. Cap. 4.
- [14] COELHO, Diogo Cesar. **PROPOSTA DE CONVERSOR PARA RASTREAMENTO DA MÁXIMA POTÊNCIA DE OPERAÇÃO DE PEQUENOS SISTEMAS DE GERAÇÃO DE ENERGIA ELÉTRICA**. 2009. 124 f. Dissertação (Mestrado) - Universidade Federal De Santa Catarina, Florianópolis, 2009. Cap. 3.
- [15] MAHDI, A. J.; TANG, W.H.; WU, Q.H.. **IMPROVEMENT OF A MPPT ALGORITHM FOR PV SYSTEMS AND ITS EXPERIMENTAL VALIDATION**. In: INTERNATIONAL CONFERENCE ON RENEWABLE ENERGIES AND POWER QUALITY, 10., 2010, Granada.
- [16] CHAPMAN, Patrick L.; ESRAM, Trishan. **COMPARISON OF PHOTOVOLTAIC ARRAY MAXIMUM POWER POINT TRACKING TECHNIQUES**. IEEE Transactions On Power Electronics, v. 22, n. 02, p.439-449, 01 jun. 2007.
- [17] SILVA, Ivan Nunes Da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **REDES NEURAIS ARTIFICIAIS PARA ENGENHARIA E CIÊNCIAS APLICADAS: CURSO PRÁTICO**. São Carlos: Artliber, 2010.
- [18] HAYKIN, Simon. **REDES NEURAIS: Princípios e Prática**. 2. ed. Porto Alegre: Artmed, 2001.

- [19] MANTOVANI, William Amaro. **UTILIZAÇÃO DE REDES NEURAIS RECORRENTES NA CARACTERIZAÇÃO DE CARGAS NÃO LINEARES EM SISTEMAS ELÉTRICOS**. 2011. 73 f. Dissertação (Mestrado) - Universidade Estadual Paulista, Ilha Solteira, 2011. Cap. 3.
- [20] GONÇALVES, Amílcar Flamarion Querubini. **CONTROLE E ANÁLISE DE CONVERSORES CC-CA CONECTADOS EM REDES DE DISTRIBUIÇÃO E UTILIZADOS EM SISTEMAS DE GERAÇÃO DISTRIBUÍDA**. 2011. 69 f. Dissertação (Mestrado) - Universidade De São Paulo, São Carlos, 2011. Apêndice A.
- [21] SAMPAIO, Patrícia Teixeira. **MODELAGEM TÉRMICA DE UM FORNO PANELA UTILIZANDO REDES NEURAIS ARTIFICIAIS**. 2006. 90 f. Dissertação (Mestrado) - Universidade Federal de Minas Gerais, Belo Horizonte, 2006. Cap. 2.
- [22] BASTOS, Renan F. et al. **REDE NEURAL ARTIFICIAL APLICADA NA BUSCA DO PONTO DE MÁXIMA POTÊNCIA EM PAINÉIS FOTOVOLTAICOS**. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 12., 2012, Campina Grande. REDE NEURAL ARTIFICIAL APLICADA NA BUSCA DO PONTO DE MÁXIMA POTÊNCIA EM PAINÉIS FOTOVOLTAICOS. p. 1276 - 1281.
- [23] INPE - INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **SONDA: Sistema de Organização Nacional de Dados Ambientais**. Disponível em: <<http://sonda.ccst.inpe.br/index.html>>. Acesso em: 13 jun. 2013.
- [24] BRAGA, Antonio De Pádua; CARVALHO, André Ponce De Leon F. De; LUDERMIR, Teresa Bernarda. **REDES NEURAIS ARTIFICIAIS - TEORIA E APLICAÇÕES**. Ltc, 2000.
- [25] VINNICIUS VIEIRA, VIII CBPE – Congresso Brasileiro de Planejamento Energético, **Energia e cidades**. 2012, Curitiba.
- [26] ANEEL. **Energia Solar**. Disponível em: <[http://www.aneel.gov.br/aplicacoes/atlas/pdf/03-Energia_Solar\(3\).pdf](http://www.aneel.gov.br/aplicacoes/atlas/pdf/03-Energia_Solar(3).pdf)>. Acesso em: 23 jun. 2013.
- [27] MACEDO, Wilson Negrão; ZILLES, Roberto. **Particularidades da geração distribuída com sistemas fotovoltaicos e sua integração com a rede elétrica**. Disponível em: <http://www.proceedings.scielo.br/scielo.php?pid=MSC0000000022004000200030&script=sci_arttext>. Acesso em: 23 jun. 2013.
- [28] ACTEWAGL. **How solar (photovoltaic) cells work**. Disponível em: <<http://kids.actewagl.com.au/education/energy/RenewableEnergy/SolarEnergy/HowSolarCellsWork.aspx>>. Acesso em: 23 jun. 2013.

- [29] **Mapa da radiação Solar do Mundo** Disponível em: <<http://www.dforcesolar.com/pt/mapa-da-radiacao-solar-do-mundo/>>. Acesso em: 23 jun. 2013.
- [30] SOLARPEDIA. **Célula Fotovoltaica**. Disponível em: <http://www.ecured.cu/index.php/C%C3%A9lula_fotoel%C3%A9ctrica>. Acesso em: 23 jun. 2013.
- [31] SCANDIG. **Sensores CCD en Escáners y Cámaras Digitales**. Disponível em: <<http://www.filmscanner.info/es/CCDSensoren.html>>. Acesso em: 23 jun. 2013.
- [32] FERRAZ, Rodolfo. **JUNÇÃO P-N: CRIAÇÃO DA REGIÃO DE DEPLEÇÃO**. Disponível em: <<http://blog.rodolfoferraz.com/2011/11/juncao-p-n-criacao-da-regiao-de.html>>. Acesso em: 23 jun. 2013.
- [33] EFEITO Fotoelétrico Disponível em: <<http://efeitofisicafotoeletrico.blogspot.com.br/>>. Acesso em: 23 jun. 2013.
- [34] HERMANO. **Perceptron em PERL**. Disponível em: <http://www.hermano.com.br/cgi-bin/index.pl?ls=./estudos/redes_neurais/Perceptron&cat=00-leia.txt>. Acesso em: 23 jun. 2013.
- [35] ABCV. **Sinapses e o livre-arbítrio**. Disponível em: <http://www.abcv.org.br/?link=eventos_noticias>. Acesso em: 23 jun. 2013.
- [36] SOLARWORLD. **SW 130/135/140 poly R6A**. Disponível em: <<http://www.solarworld-usa.com/system-designers/~media/Global/PDFs/datasheets/sunmodule-off-grid-solar-panel-130-140-poly-r6a.pdf>>. Acesso em: 23 jun. 2013.

A. ANEXOS

A-I. ALGORITMO DE OBTENÇÃO DE R_p E R_s ATRAVÉS DE ALGORITMOS GENÉTICOS

```
clear all
clc

Voc = 21.9;           %V open circuit
Vmpp = 17.7;          %V on MPP
Isc = 7.65;           %I short-circuit
Impp = 7.38;          %I on mpp

Rs_min = 0;           %Maximum value for Rs
Rs_max = (Voc - Vmpp)/Impp; %Maximum value for Rs
Rp_min = Vmpp/(Isc-Impp) - Rs_max; %Maximum value for Rp
Rp_max = 1e8;
vars = 2;
%[Rs Rp]
LB = [Rs_min Rp_min];
UB = [Rs_max Rp_max];
[x,fval,flag] = ga(@PVfitnessFunc,vars,[],[],[],[],LB,UB)
Rs = x(1)
Rp = x(2)
```

A-II. FUNÇÃO QUE CALCULA A TENSÃO DE MÁXIMA POTÊNCIA DO PAINEL PARA UM DADO VALOR DE TEMPERATURA E RADIAÇÃO SOLAR:

```
function [Pmax, Vmax] = PVfuncMpp(S,T)

clear I
clear V
clear P
clear Pmax
clear Vmax
clc
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%calculating parameters through the datasheet

%Informing parameters:
Ns = 36; %Number of cells in series
Pmpp = 130; %Pot on MPP
Voc = 21.9; %V circuito aberto
Vmpp = 17.7; %V on MPP
Isc = 7.65; %I curto-circuito
Impp = 7.38; %I on mpp
TCi = 0.034; % %/K - Isc
Eg = 1.12; %Band Gap Si (mono, poli, amorf)
q = 1.60218e-19; %Elementary Charge (C)
Kbolt = 1.38065e-23; %Cte Boltzman
Tr = 25; %T on STC (°C)
Tr = Tr + 273.16; %T in K
```

```

Sr = 1000; %S on STC (W/m2)
Vtr = Kbolt*(Tr)/q; %Vtr in V

%Obtained Parameters (GA)
Rs = 3.7851e-5;
Rp = 7.4175e7;

%Calculating Parameters
A = ((Vmpp-Voc)/36)/(Vtr*log((Isc-Imp-Vmpp/(36*Rp))/(Isc-Voc/(36*Rp))))
Iso = (Isc-Voc/(36*Rp))/(exp(Voc/(36*A*Vtr))-1)
KT = TCi*Isc/100;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%photovoltaic cell simulation
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

T=T+273.16; %convert T from °C to K

Is = Iso*((T/Tr)^3)*exp(q/(A*Kbolt)*Eg*(1/T-1/Tr));

%starting iterative method
nmax = 1000; %number of iterations
incv = 24/nmax; %increment of V
V = 0:incv:24;
I = zeros(1,size(V,2));
Iph = (Isc + KT*(T-Tr))*S/Sr; %calculate Iph (no V,I dependence)
for n = 1:(size(V,2))
    f = 1; %starting result for the while
loop
    while (abs(f) > 1e-5)
        Id = Is*(exp((q/(A*Kbolt*T))*(V(n)/Ns+I(n)*Rs))-1); %calculates
        Id (V,I dependence)
        Ip = (V(n)/Ns+I(n)*Rs)/Rp; %calculates Ip (V,I
        dependence)
        f = I(n) - (Iph - Id - Ip); % if I = Iph - Id - Ip, so the
        function result must to return 0 on the correct (V,I) point.
        df = 1 +
        Is*(q/(A*Kbolt*T))*Rs*(exp((q/(A*Kbolt*T))*(V(n)/Ns+I(n)*Rs))) + Rs/Rp;
        I(n) = I(n) - f/df;
    end
    if I(n) < 0
        I(n) = 0;
    end
end
P = V.*I; %plot of the IxV and PxV curves
[Pmax,Nmax] = max(P);
Vmax = V(Nmax);

```

A-III. REDE NEURAL ARTIFICIAL MLP COM FUNÇÃO DE ATIVAÇÃO SIGMOIDE – TREINAMENTO E VALIDAÇÃO

```

clear all
clc

%read training samples
DATA = xlsread('D:\training.xls','Normalized6');
in = DATA(:,1:2)
out = DATA(:,3)

```

```

%starting variables
k = 0;           %counter
neuro_in = 9;    %input neurons

train = 2299;    %training samples
valid = 47;      %validation samples
n_in = 2;        %inputs
n_out = 1;       %n saidas

n = 0.95;        %learning factor
eps = 1e-3;      %eps - precision
em = 10;         %error med
em_aux = 20;     %auxiliar error

% weights initialization
% Format:
% Win(x,y) -> layer index
% x - neuron index
% y - in connected
for x = 1:neuro_in
    for y = 1:n_in %1:3
        W1(x,y) = rand;
    end
end
for x = 1:n_out
    for y = 1:neuro_in
        W2(x,y) = rand;
    end
end
W1o = W1
W2o = W2
tic; %algorithm time execution, start counter
k = 0;
while ((em > eps))
    em_aux = em;
    %start training
    for a = 1:train %1:200
        %forward propagation
        for x = 1:neuro_in %1:30
            var1 = 0; %var
            for b = 1:n_in %1:3
                var1 = var1 + W1(x,b)*in(a,b);
            end
            U1(x) = var1;
            Y1(x) = 1./(1+exp(-1.*U1(x))); %sigmoide function
        end
        for x = 1:n_out %1:1
            var1 = 0;
            for b = 1:neuro_in %1:30
                var1 = var1 + W2(x,b)*Y1(b)';
            end
            U2(x) = var1;
            Y2(x) = 1./(1+exp(-1.*U2(x)));
        end
        %backpropagation
        %weights ajusting
        Yd = out(a,1:n_out); %read desired output
        for x = 1:n_out

```

```

        dY2(x) = (Yd(x) -
Y2(x)) * (exp(U2(x))) / ((exp(U2(x))^2)+2.*exp(U2(x))+1)); %sigmoide derivative
-> calculates g'(u)*(d-y)
    end
    for x = 1:n_out
        for y = 1:neuro_in
            W2(x,y) = W2(x,y)+n*dY2(x)*Y1(y);
        end
    end
    for x = 1:neuro_in
        dY1(x) =
sum(dY2*W2(:,x))*exp(U1(x))/((exp(U1(x))^2)+2*exp(U1(x))+1); %derivada da
signoide
    end
    for x = 1:neuro_in
        for y = 1:n_out
            W1(x,y) = W1(x,y) + n*dY1(x)*in(a,y);
        end
    end
    %errors
    error = abs(Y2-out(a,:));
    sqe = error*error';
    mseout(a) = sqe/n_out;
end
k = k + 1;
mse = sum(mseout)/train;
p_erro(k) = mse;
em = mse;
end
%end training
t = toc
tminutos = t/60;

%plot
plot(p_erro);
mse
k

%validation: results
VDATA = xlsread('D:\validation.xls','Normalized1');
val_in = VDATA(:,1:2);

for a = 1:valid
    for x = 1:neuro_in
        var1 = 0;
        for b = 1:n_in
            var1 = var1 + W1(x,b)*val_in(a,b);
        end
        U1(x) = var1;
        Y1(x) = 1./(1+exp(-1.*U1(x))); %sigmoide function
    end

    for x = 1:n_out
        var1 = 0;
        for b = 1:neuro_in
            var1 = var1 + W2(x,b)*Y1(b)';
        end
        U2(x) = var1;
        Y2(x) = 1./(1+exp(-1.*U2(x)));
    end
end

```

```
    result(a,:) = Y2;

    error = result(a,:) - out(a,:);
    sqe = error*error';
    mseout(a) = sqe/n_out;
end
mse_final = sum(mseout)/valid
W1;
W2';
result;

%xlswrite('D:\validation.xls',result,'Results','F');
```