

CONTROLE DE TEMPERATURA EM CÉLULAS SOLARES UTILIZANDO PASTILHA TERMOELÉTRICA *PELTIER*

RAPHAEL QUEIROZ*, ANDREI BATTISTEL*, GERMANO MAIOLI PENELLO†

**Departamento de Eletrônica e Telecomunicações,
DETEL, Universidade do Estado do Rio de Janeiro*

†Instituto de Física, Universidade Federal do Rio de Janeiro

Emails: queiroz.rphl@gmail.com, andrei.battistel@gmail.com, gpenello@if.ufrj.br

Abstract— Tests of energy efficiency of solar cells require good control performance in terms of temperature regulation of the photovoltaic panel. This work proposes the temperature control using a *Peltier* thermoelectric chip, on a copper support to serve as a support for the solar cells for analysis. In order to overcome the difficulty of obtaining a physical model and to deal with parametric uncertainties and perturbations, a mathematical modeling based on identification techniques using input and output data is used. Two control systems algorithms, a Proportional-Integral Controller (PI) and a strategy using machine learning (Machine Learning) are proposed. Experimental results illustrate the obtained performance for each technique.

Keywords— PI, Arduino, Temperature Control, *Machine Learning*, *Peltier*, Solar Cell.

Resumo— Testes de eficiência energética de células solares exigem um bom desempenho de controle em termos de regulação da temperatura do painel fotovoltaico. Neste trabalho é proposto o controle de temperatura, utilizando uma pastilha termoeletrica *Peltier* em um suporte de cobre que servirá de suporte para as células solares a serem caracterizadas. A fim de contornar a dificuldade de obter uma modelagem física e para lidar com as incertezas paramétricas e perturbações, utiliza-se uma modelagem matemática baseada em técnicas de identificação usando dados de entrada e saída. São propostas duas estratégias de controle do sistema, um controlador Proporcional-Integral (PI) e uma estratégia utilizando aprendizado de máquinas (*Machine Learning*). O desempenho das técnicas será ilustrado por meio de resultados experimentais.

Palavras-chave— PI, Arduino, Controle de temperatura, *Machine Learning*, *Peltier*, Célula solar.

1 Introdução

A eficiência da conversão de energia em painéis solares fotovoltaicos é diretamente influenciada pela temperatura de operação, uma vez que a potência máxima obtida decresce com o aumento da temperatura para uma mesma condição de radiação solar. Diversos estudos foram produzidos no sentido de obter relações entre temperatura e eficiência de painéis solares, levando em conta uma série de variáveis como o material do painel, o arranjo utilizado e até questões ambientais e geográficas. Uma revisão sobre o assunto pode ser encontrada em (Skoplaki and Palyvos, 2008) onde são discutidas diversas correlações entre temperatura e eficiência. Como exemplos da relevância dessa discussão, de acordo com (Skoplaki and Palyvos, 2008), células de silício cristalino apresentam uma perda de eficiência em torno de 0.45% para cada acréscimo de 1°C .

Em vista desta questão, diversos trabalhos propõem alternativas para melhorar o desempenho de painéis solares utilizando diferentes estratégias de resfriamento, levando em consideração aspectos como o custo-benefício e consumo mínimo de energia. São exemplos técnicas que empregam água como elemento resfriador (Moharra et al., 2013), técnicas passivas (Li et al., n.d.), (Wu and Xiong, 2013) e dissipadores de calor resfriados por ar. Uma revisão mais completa pode ser encontrada em (Bahaidarah et al., 2015).

Embora a escolha de uma técnica adequada de resfriamento de painéis solares envolva uma série de fatores, entre eles o próprio consumo de energia necessário para o resfriamento; estas técnicas objetivam em geral uma melhora de desempenho em termos de eficiência, e não necessariamente um controle de temperatura preciso. Por outro lado, em fases de desenvolvimentos e testes de painéis, arranjos e/ou algoritmos voltados para a geração de energia solar, um bom controle de temperatura é necessário a fim de realizar certos ensaios. Isto é, de maneira a tornar possível a análise das variáveis de interesse em diferentes cenários em determinadas faixas de temperatura.

Desta forma, o controle de temperatura de células solares, possivelmente expostos à variações externas, torna-se um problema de controle de sistemas incertos e sujeitos a perturbações. A obtenção de modelos matemáticos está sujeita tanto a incertezas paramétricas como a dinâmicas não-modeladas, e/ou com a presença de efeitos não lineares. Ainda, um controlador adequado deve ser robusto a variações da temperatura ambiente varie e/ou da temperatura na região em controle.

Uma estratégia possível para o controle de temperatura em células solares consiste em utilizar uma pastilha termoeletrica *Peltier*, capaz de reduzir a temperatura em uma região específica: um bloco de cobre (ou alumínio) de 6cm x 6cm x 1,5cm que servirá de suporte para as células solares em teste. A modelagem deste sistema apre-

senta alguma complexidade como a dificuldade em obter uma modelagem física precisa do *Peltier*, além de incertezas nas características físicas dos itens resfriados, que podem inclusive serem alterados em uma aplicação prática. Isto é, deseja-se obter um controlador tão robusto quanto possível mesmo na presença de incertezas.

Neste trabalho são apresentadas duas abordagens distintas para resolver esse problema. A primeira abordagem utilizada consiste em obter modelos matemáticos de entrada-saída por meio de técnicas de identificação de sistema, contornando assim a dificuldade de obtenção de uma modelagem física. A partir dos modelos obtidos, o controlador pode ser projetado utilizando técnicas conhecidas. Por fim, analisou-se o desempenho do sistema utilizando algoritmos de *Machine Learning*, de forma a controlar o sistema sem a necessidade de uma modelagem explícita, utilizando para isso um conjunto de dados experimentais.

2 Formulação do Problema

O sistema de interesse está representado na Fig. 1 e é composto por uma placa de cobre (ou alumínio), uma pastilha termoeletrica *Peltier* e um dissipador de calor. Para medir a temperatura na placa, é utilizado um sensor de temperatura (DS18B20 (Dal, n.d.)), localizado no centro da placa de cobre.




Figura 1: Disposição física dos componentes do sistema em estudo.

A pastilha termoeletrica *Peltier*, cuja função é resfriar a placa em estudo, é constituída por duas chapas de material isolante com uma malha de material condutor na superfície interna de cada chapa. Entre as malhas do material condutor, estão localizados diversos semicondutores do tipo *n* e *p*. Em função da ordenação do material semicondutor e o fluxo contínuo de corrente gerada por uma fonte DC, acontece o efeito *Peltier* (Thakkar Mohit Pravinchandra, 2015), resfriando um lado da placa e esquentando o outro e transformando assim energia elétrica em térmica. A Fig. 2 ilustra a configuração e o funcionamento de uma pastilha *Peltier*.




Figura 2: Esquema do funcionamento da pastilha *Peltier*.

2.1 Disposição física dos componentes

Pela característica da pastilha *Peltier* de resfriar um de seus lados e consequentemente aquecer o outro, a placa de cobre do sistema onde é medida a temperatura, é colocada sobre a superfície a ser resfriada. Em contato com a superfície aquecida coloca-se um dissipador de calor. Este item é de importância fundamental a fim de evitar que o calor gerado influencie a superfície do *Peltier* a ser resfriada, diminuindo a eficiência do resfriamento e também a vida útil do componente.

Essa configuração foi escolhida uma vez que, em geral, a temperatura ambiente está acima da temperatura que se deseja manter a placa. Caso a temperatura que se deseja alcançar esteja acima da temperatura ambiente, deve-se inverter a polaridade da fonte DC de tensão. Em resumo, o *Peltier* pode ser usado para esquentar e resfriar a região onde se deseja controlar a temperatura. Neste projeto será realizado o estudo do controle de resfriamento, apenas.

As Figs. 3, 4 e 5 mostram o protótipo com o qual foram realizados os experimentos.




Figura 3: Visão lateral do sistema utilizado



Figura 4: Visão superior do sistema utilizado




Figura 5: Visão superior do sistema de controle - *Arduino* e circuito eletrônico (protótipo do sistema)

2.2 Configuração do sistema de controle

A fim de controlar a temperatura da pastilha térmica, projetou-se um circuito eletrônico com duas funções principais:

- Isolar o *Arduino* (circuito responsável pela parte lógica) do circuito de potência (responsável pelo controle da corrente que passa pelo *Peltier*).
- Limitar variações bruscas de tensão e corrente no *Peltier* evitando redução da vida útil do *Peltier*.

A Fig. 6 mostra o circuito eletrônico utilizado para realizar o controle de corrente no *Peltier*. Ao lado direito do optoacoplador localiza-se a parte de potência do circuito.

Na representação esquemática, todo o sistema (*Peltier*, placa de cobre/alumínio e dissipador) é representado em um círculo com a letra “P” dentro, simbolizando a pastilha *Peltier*, a placa de cobre e o dissipador de calor.




Figura 6: Sistema eletrônico de comunicação e controle de temperatura

O circuito da Fig. 6 contém um filtro passa baixa. Esse filtro é responsável por evitar variações bruscas de corrente no sistema, assim evitando ruídos que poderiam influenciar no comportamento do sistema.

Escrever uma equação de transferência para entender como o circuito funciona é possível, porém complexo. Essa dificuldade é encontrada principalmente pelos componentes do sistema (*Peltier*, placa de cobre/alumínio e dissipador) serem relativamente complexos. Em virtude

desta dificuldade, busca-se obter técnicas que permitam controlar a temperatura no sistema sem conhecer de maneira precisa os parâmetros e características físicas de todos os elementos do sistema.

3 Identificação de Sistemas

Em vista da dificuldade já discutida de se obter uma modelagem física do sistema, utiliza-se uma abordagem de identificação de sistemas utilizando dados de entrada e saída (Ljung, 1999). Os objetivos são tanto a obtenção de um modelo aproximado do sistema que permita projetar um controlador adequado, quanto possibilitar testes de simulação numérica antes de implementar os controladores na planta.

Para a descrição de um modelo matemático do sistema em estudo, foi utilizado o modelo auto-regressivo com entradas externas (ARX do inglês *autoregressive with exogenous inputs*). O modelo geral que descreve esse tipo de modelo é visto na equação 1 (Aguirre, 2007). Onde $A(q)$ e $B(q)$ são polinômios, $u(k)$ é a entrada do sistema e $v(k)$ o ruído do sistema e q^{-1} representa o operador atraso tal que para um sinal $y(k)$, tem-se $q^{-1}y(k) = y(k-1)$

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}v(k) \quad (1)$$

Vale ressaltar que no modelo ARX, o ruído $v(k)$ é acrescido à saída do sistema, modelos do tipo erro na equação.

Para obter um modelo ARX, utilizou-se o estimador de mínimos quadrados (MQ). Pode-se escrever o modelo ARX da Eq. 1 na forma da Eq. 4 (Aguirre, 2007)

$$\mathbf{y} = \psi\theta + \xi \quad (2)$$

sendo ψ é denominada de *matriz de regressores*, $\psi(k-1) = [y(k-1) \dots y(k-n_y) \ u(k-1) \dots u(k-n_u)]$ e $u(k)$ são amostras do sinal de entrada, e $y(k)$ do sinal de saída e n_y e n_u são números inteiros. A ordem do modelo é determinada por n_y e n_u e é uma escolha de projeto.

Uma vez escolhida a estrutura, o estimador de MQ é utilizado para obter o conjunto de parâmetros estimados $\hat{\theta}_{MQ}$

$$\hat{\theta}_{MQ} = [\psi^T \psi]^{-1} \psi^T \mathbf{y} \quad (3)$$

que minimiza o erro quadrático entre a saída real e a saída obtida com o modelo estimado. Isto é, considerando a saída estimada abaixo

$$\hat{\mathbf{y}} = \psi \hat{\theta}_{MQ} \quad (4)$$

tem-se o erro dado por $\xi = y - \hat{y}$. Pode-se demonstrar que a solução de MQ minimiza o quadrado

do erro $\xi(N)$, onde N é o número de amostras do sinal, dado pela função custo da Eq. 5.

$$J_{MQ} = \sum_{i=1}^N \xi(i)^2 \quad (5)$$

O sinal de entrada utilizado na identificação é um sinal binário pseudo aleatório (PRBS). A partir destes dados foram obtidos diversos modelos matemáticos para o sistema a partir de diferentes escolhas de estruturas para o regressor. Em seguida, um conjunto de dados diferente do utilizado na identificação foi utilizado para validar os modelos obtidos, de maneira a escolher aqueles com melhor desempenho em termos de ajuste dos dados. A Fig. 7 representa o resultado de validação do modelo escolhido.

A função de transferência escolhida para representar o sistema é mostrada na equação 6. Os parâmetros de PI escolhidos são: $P = 3.191$ e $I = 0.04546$.

$$H(q) = \frac{0.001233q^{-1} - 0.002458q^{-2} + 0.001224q^{-3}}{1 - 3.916q^{-1} + 5.749q^{-2} - 3.75q^{-3} + 0.9172q^{-4}} \quad (6)$$




Figura 7: Validação do modelo utilizando dados do experimento, comparando a saída medida y (vermelho) com a saída estimada $\hat{y}$ (azul).

De posse de um modelo identificado e validado, é possível simular o comportamento do sistema e portanto simular um controle para o sistema. O diagrama de blocos do sistema é mostrado na Fig. 8, onde toda parte de controle, PI e a geração do PWM , é processada e gerada pelo *Arduino*. O bloco do *Peltier Plant* corresponde à planta de interesse e a saída é a temperatura a ser controlada.




Figura 8: Diagrama de blocos do sistema

Com o sistema de controle da Fig. 8 foi possível projetar o controlador PI de maneira adequada. O desempenho do controlador é visto na Fig. 9.




Figura 9: Resultado experimental utilizando controlador PI com setpoint em $20^{\circ}C$.

A fim de avaliar a capacidade de rejeição a perturbações, dois ensaios foram realizados colocando-se perturbações no sistema. Nas Figs. 11 e 10, são utilizados dois tipos diferentes de distúrbios. No primeiro, foi posto sobre a placa de cobre uma placa de alumínio ($6\text{cm} \times 6\text{cm} \times 1\text{cm}$) com temperatura ambiente de $27^{\circ}C$ por um período de 25s. O segundo teste de distúrbio, foi posto sobre a placa de cobre a mesma placa de alumínio com temperatura ambiente de $26^{\circ}C$ até o sistema atingir o equilíbrio.




Figura 10: Resultado experimental utilizando controlador PI. Setpoint em $20^{\circ}C$. Distúrbio momentâneo de 25s gerado pela placa de alumínio após 14 minutos. Seta mostrando o momento de geração do distúrbio.

4 Machine Learning

Arthur Samuel (1959) definiu que o *Machine Learning* (Aprendizado de Máquina) é o campo de estudo no qual concede ao computador habilidade de aprender sem ser explicitamente programado. No caso em estudo, aprender significa conseguir, a partir de uma quantidade de dados, escolher um valor de PWM para o qual a temperatura do sistema chegará à temperatura estipulada como *setpoint*.




Figura 11: Resultado experimental utilizando PI e método ARX de identificação de sistemas. Setpoint em 20°C. Distúrbio prolongado gerado pela placa de alumínio após 14 minutos. Seta mostrando o momento de geração do distúrbio.

Esse método requer pouco conhecimento do funcionamento do sistema, pois o algoritmo aprende a controlar o sistema com base em suas respostas.

Neste trabalho foi utilizado a técnica de aprendizado supervisionada (*supervised learning*) (Pedregosa et al., 2011). Essa técnica consiste em entregar ao algoritmo uma certa quantidade de “dados corretos”, mostrando como de fato o sistema responde. Baseado nesses dados, o algoritmo tentará generalizar o comportamento do sistema. Essa tentativa de generalizar pode ser entendida como uma hipótese. De maneira geral, o algoritmo deve tentar prever para determinada entrada a sua resposta (saída) correspondente.

A Fig. 12 represente como o fluxo ocorre para o algoritmo.




Figura 12: Fluxograma de funcionamento *Machine Learning* - regressão linear. “X” corresponde a entrada de dados e “Y” corresponde a saída real de dados.

Os dados são processados através do algoritmo de aprendizado de máquina, então é sugerido um resultado. A sugestão é baseada nas equações 7 e 8.

$$h_{\theta}(x) = \theta_0 + \theta_1 x \quad (7)$$

$$J(\theta_0, \theta_1) = \frac{1}{2n} \sum_{x=1}^n (h(x)^i - y^i)^2 \quad (8)$$

A ideia básica é tornar a hipótese $h_{\theta}(x)$ o mais próximo possível do valor real y^i , onde i representa o número da interação de aprendizado. Para que esse objetivo seja alcançado, o valor de $J(\theta_0, \theta_1)$ deve ser o menor possível. $J(\theta_0, \theta_1)$ é denominada função de custo (*cost function*).

O que faz o algoritmo se adaptar ao sistema é a repetição do fluxo da Fig. 12. Cada vez que acontece essa repetição os dados são treinados novamente, porém, o próximo treinamento sempre terá mais dados do que o anterior, ou seja, a previsão se torna mais precisa.

Utilizando a biblioteca *sklearn* desenvolvida em *python* foi implementado o algoritmo para a Regressão Linear. O algoritmo foi treinado com dados aleatórios colhidos do sistema em estudo (um pouco menos de 20 minutos de leitura do comportamento do sistema). Após isso, foi determinado um valor de *setpoint*, dado a temperatura atual da placa e então o algoritmo tentou prever qual seria o valor de PWM seria adequado para se enviar para o sistema.




Figura 13: Resultado controle de temperatura com *Machine Learning*. Setpoint 20°C

O teste mostrado na Fig. 14 mostra como o controle desenvolvido com *Machine Learning* se comporta com distúrbios externos. Para esse teste de distúrbio, foi posto sobre a placa de cobre uma placa de alumínio (6cm x 6cm x 1cm) com temperatura ambiente de 27 °C até o sistema, incluindo a placa de alumínio, atingir a temperatura desejada.

Seu desempenho se mostrou aceitável considerando o desconhecimento prévio do sistema, e a velocidade para aprender qual seria a temperatura a se escolher. A variação de temperatura do sistema ficou em torno de $\pm 1^\circ\text{C}$, para a aplicação em análise o modelo deve ser refinado.




Figura 14: Resultado controle de temperatura com *Machine Learning* com distúrbio externo. Distúrbio gerado após 17 minutos. Setpoint 20°C

5 Discussão dos Resultados

A proposta de controlar a temperatura em uma região específica sem conhecimento prévio do modelo dos componentes que compõem o sistema apresenta uma série de desafios e dificuldades. Diversas técnicas podem ser implementadas nessa tarefa. Neste artigo foram escolhidas as técnicas de identificação de sistemas para projetar um controlador a partir de um modelo identificado e uma técnica de *Machine Learning*.

Como há diferenças intrínsecas entre o comportamento real do sistema e seus modelos matemáticos, a operação e controle do sistema baseado em modelos está naturalmente sujeita possíveis erros. Por outro lado, utilizando-se de técnicas adequadas esses erros podem ser minimizados. Nos resultados obtidos, ficou claro o fundamental papel da descrição matemática do sistema para o controle. De posse dessa descrição, foi projetado um controle com bom desempenho de controle para a temperatura em uma região esperada. A identificação de sistemas para a modelagem, mesma na ausência de conhecimento sobre parte das características do sistema em análise, permitiu a obtenção de bons resultados.

No que diz respeito às técnicas de *Machine Learning*, é interessante ressaltar que o algoritmo permite controlar a temperatura desse sistema de maneira satisfatória a temperatura do sistema sem conhecimento prévio dos componentes, sendo necessário apenas a obtenção de dados experimentais para aplicação do algoritmo.

No experimento em análise foi utilizada uma pequena quantidade de informações sobre o sistema. É esperado que ao incrementar o conhecimento do sistema, bem como possivelmente aplicar técnicas diferentes de *Machine Learning*, se possa obter um melhor desempenho de controle. É possível adequar quaisquer características que podem influenciar o sistema, desde que possam ser mensuradas, tais como temperatura ambiente, índice de umidade, dentre tantas outras característi-

cas pertinentes ao objetivo escolhido. A vantagem a ser explorada nas técnicas de *Machine Learning* consiste justamente na ampla capacidade de fazer associações com dados, trazendo por meio desses dados informações pertinentes ao sistema de interesse.

Como propostas de trabalhos futuros, pode-se implementar uma estratégia de controle adaptativo a fim de contornar de maneira mais precisa as incertezas paramétricas e dinâmicas não-modeladas.

6 Conclusões

Em comparação com o controle PI, o controle gerado com *Machine Learning* se mostrou menos eficaz quando o objetivo é manter a temperatura estável. A capacidade de criarmos um controle com *Machine Learning* com poucas informações sobre o sistema é sem dúvidas um dos pontos fortes da técnica, poupa tempo de projeto e se adapta à variações com mais facilidade. Escolher qual seria o modelo mais adequado é uma questão de aplicação, já que ambas as técnicas se mostraram eficazes em seu objetivo de controle.

Agradecimentos

Os autores agradecem pelo suporte financeiro fornecido pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e pela Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ).

Referências

- Aguirre, L. A. (2007). *Introdução à identificação de sistemas*, Editora UFMG, Belo Horizonte.
- Bahaidarah, H. M., Baloch, A. A. and Gandhidasan, P. (2015). Uniform cooling of photovoltaic panels: A review, pp. 1520 – 1544.
- Dal (n.d.). *DS18B20-PAR 1-Wire Parasite-Power Digital Thermometer*.
- Li, W., Shi, Y., Chen, K., Zhu, L. and Fan, S. (n.d.). Passive cooling of solar cells with a comprehensive photonic approach, pp. 847 – 850.
- Ljung, L. (1999). *System Identification: Theory for the User*, Prentice Hall; 2 edition, Sweden.
- Moharra, K., Abd-Elhady, M., Kandil, H. and El-Sherif, H. (2013). Enhancing the performance of photovoltaic panels by water cooling, pp. 869 – 877.

- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research* **12**: 2825–2830.
- Skoplaki, E. and Palyvos, J. (2008). On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations, pp. 614 – 624.
- Thakkar Mohit Pravinchandra, J. P. (2015). *Peltier cooling module*, Master’s thesis, PANDIT DEENDAYAL PETROLEUM UNIVERSITY.
- Wu, S. and Xiong, C. (2013). Passive cooling technology for photovoltaic panels for domestic houses, pp. 118 – 126.