

SISTEMA DE MONITORAMENTO IOT DA IRRADIÂNCIA SOLAR COM LDR APLICANDO APRENDIZAGEM DE MÁQUINA

Dionízio Porfírio de Assis

Leticia de Oliveira Santos

Breno Bezerra Freitas – brenobf93@gmail.com

Renata Imaculada Soares Pereira

Paulo Cesar Marques de Carvalho

Universidade Federal do Ceará, Departamento de Engenharia Elétrica

1.1. Recurso solar e meteorologia da radiação solar

Resumo. O estudo propõe o uso de Resistor Dependente de Luz (*Light Dependent Resistors - LDRs*) como alternativa de baixo custo e alta eficiência aos piranômetros. Oferece propostas de um modelo capaz de converter os valores medidos pelo LDR em dados de irradiância solar. A pesquisa descreve o desenvolvimento de um sistema de monitoramento baseado em Internet das Coisas utilizando a plataforma ThingSpeak. Nesse sistema, os sinais analógicos de tensão do LDR, que varia sua resistividade de acordo com a luminosidade, são captados e enviados ao servidor para comparação com os valores medidos pelo piranômetro (W/m^2). Foram coletados dados desses equipamentos por três semanas, limitados ao intervalo diário de funcionamento do piranômetro. Em uma análise inicial, a correlação entre as leituras revelou um coeficiente de determinação (R^2) de 0,87, evidenciando a correlação existente entre as medições do LDR e do piranômetro. No entanto, destaca-se que o LDR não é o mais adequado para medições de irradiância solar, mas foi empregado aqui para avaliar o desempenho dos métodos de aprendizado de máquina. Assim, foram obtidas 12.565 medições, das quais 80% foram utilizadas para treinamento e 20% para testes dos modelos aplicados, incluindo Regressão Polinomial (RP), Support Vector Machine (SVM) e Rede Neural Artificial (RNA). Os resultados indicam que SVM e RNA obtiveram R^2 de 0,92 nos testes, superando a RP, que alcançou 0,9 na capacidade de prever a irradiância solar com base no LDR. O SVM se destacou devido à menor complexidade de uso e ao tempo de treinamento mais rápido. No entanto, ao analisar o erro médio entre as medidas do piranômetro e as previstas pelos modelos, observou-se que a RP apresentou erro de 22,48%, SVM registrou 18,48% e RNA um erro de 20,43%, corroborando o fato de que este sensor não é o mais adequado para este fim.

Palavras-chave: Monitoramento Fotovoltaico, Irradiância Solar, Monitoramento de Baixo Custo.

1. INTRODUÇÃO

A transição para uma matriz energética sustentável, com foco na descarbonização e na neutralização das emissões de gases de efeito estufa, é uma necessidade global premente. Dentro desse contexto, o monitoramento da geração de eletricidade por fonte fotovoltaica (FV) desempenha um papel crucial para maximizar a eficiência desses sistemas. Nesse sentido, uma variável crítica para o desempenho dos módulos FV é a irradiância solar. O presente artigo visa explorar alternativas acessíveis, de baixo custo e eficazes ao uso do piranômetro para monitorar a irradiância solar. Embora alguns estudos tenham proposto o uso de sensores de luz, como os *Light Dependent Resistors* (LDRs), como alternativas viáveis aos piranômetros convencionais devido à capacidade desses sensores de alterar sua resistência em função da intensidade luminosa. É importante ressaltar que o LDR, embora útil em alguns contextos, pode não ser o sensor mais adequado para essa finalidade em todos os casos.

Deve-se notar que a irradiância emitida pelo Sol chega à Terra é distribuída em uma extensa faixa de comprimentos de onda. Portanto, para que um sensor seja capaz de medir com precisão a irradiância, é necessário que ele seja capaz de captar uma ampla parte desse espectro. A Fig. 1 apresenta uma comparação dos comprimentos de onda captados por diferentes tipos de sensores e os emitidos pelo Sol, destacando a importância de escolher um sensor que possa captar adequadamente esse espectro diversificado.

É notório que a faixa coletada pelo LDR não compreende totalmente o espectro emitido pelo Sol, porém a resposta do LDR acima de 10% está dentro de uma faixa de 350 nm a aproximadamente 730 nm. Mesmo com a resposta em comprimentos de onda reduzida, é um dispositivo extremamente atraente devido ao seu baixo custo em comparação com outros sensores, mesmo que perca na amplitude da captação das ondas. Este fato justifica o estudo para identificar a viabilidade do uso do LDR como alternativa à utilização do piranômetro. Por este motivo, buscou-se na literatura por trabalhos focados em sistemas de monitoramento e aquisição de dados, bem como modelos de utilização do LDR para este fim.




Figura 1 - Resposta do espectro de irradiância dos sensores: piranômetro de fotodiodo, piranômetro de termopar e LDR; e da irradiância solar ao nível do mar. Adaptado de BARROS (2018).

Visando a instalação de um sistema de monitoramento de baixo custo, é proposto por Pereira (2019) um sistema de dados de três plantas FV: uma em Fortaleza, outra em Maracanaú e outra em Colônia – Alemanha e variáveis meteorológicas. O sistema Internet das Coisas (*Internet of Things* – IoT) propõe a redução de custos se comparado ao monitoramento baseado em *dataloggers* e sensores comerciais. Nele, foram utilizados dois microcontroladores, um ESP8266 e um ESP32. As variáveis monitoradas foram: velocidade do vento, temperatura dos módulos, temperatura ambiente, irradiância solar e umidade relativa do ar, utilizando a rede WiFi e coletando os dados a cada minuto. As informações coletadas são enviadas para um servidor MySQL na Nuvem e foi desenvolvido um ambiente *online* próprio em *Hypertext Preprocessor* (PHP) para consulta dos dados e monitoramento em tempo real.

Já Barros *et al.* (2018) implementam um sistema capaz de medir a irradiância solar utilizando sensores de baixo custo. O protótipo consistia em três LDRs conectados a resistores com resistências diferentes. As tensões elétricas de cada um foram coletadas por um Arduino e enviadas a um *DataLogger*, assim como a irradiância medida por um piranômetro convencional. Com esses dados, foi possível construir 5 modelos matemáticos baseados em regressão polinomial, um para cada faixa de irradiância. O estudo revelou um ajuste R^2 de aproximadamente 0,91 para os dados de validação. Entretanto, apenas o modelo de regressão polinomial foi utilizado, não sendo comparado com nenhum outro modelo matemático diferente.

Em Vieira *et al.* (2015) é estudada a eficiência de três tipos diferentes de LDRs na medição da irradiância solar. Esses sensores foram associados às resistências de 10 k Ω , e as suas tensões foram coletadas para serem correlacionadas com a saída de um sensor de irradiância solar portátil, com o objetivo de obter uma equação de conversão da tensão para W/m². O LDR de 5 mm, com o melhor coeficiente de determinação, foi escolhido para gerar o modelo matemático baseado em regressão exponencial. Devido à coleta manual dos dados de irradiância por meio de um piranômetro portátil, houve comprometimento no sincronismo dos dados coletados. Além disso, apenas um modelo matemático foi utilizado para desenvolver a equação de conversão entre a irradiância e a tensão do LDR.

O presente artigo pretende contribuir para este tema, introduzindo um sistema de monitoramento IoT com uma ESP32 utilizando a rede WiFi. Desta forma, o sistema é capaz de coletar dados vindos do piranômetro e do LDR de forma sincronizada para que possam ser utilizados de maneira mais eficiente por ferramentas de tratamento de dados. Além disso, os dados vindos do sistema de monitoramento receberam tratamento para que pudessem ser utilizados na construção de um modelo capaz de converter a resposta do LDR em irradiância solar.

Na implementação do sistema de monitoramento, os sensores foram integrados ao microcontrolador, sendo necessário amplificar o sinal para o piranômetro. Para a incorporação do LDR, foi configurado um circuito divisor de tensão, colocando o sensor em série com um resistor de 100 Ω com 5% de tolerância, enviando a tensão resultante para a ESP32. Esses dados são transmitidos em tempo real para o servidor de aplicação ThingSpeak, garantindo total sincronismo na obtenção das informações. Adicionalmente, conduziu-se uma avaliação abrangente de diversos métodos de tratamento de dados com o objetivo de construir um modelo capaz de converter as respostas do LDR em medidas de irradiância solar. Foram explorados e analisados diferentes modelos, incluindo a Regressão Polinomial (RP), o *Support Vector Machine* (SVM), e uma Rede Neural Artificial (RNA).

2. METODOLOGIA

O projeto de monitoramento de irradiação de baixo custo baseado no LDR foi dividido em duas partes: inicialmente, o desenvolvimento do sistema de monitoramento utilizando um sensor de baixo custo e um piranômetro para associar as leituras do LDR com o equivalente em irradiação solar; e o desenvolvimento de modelos de aprendizado de máquina para correlacionar as medições. Na Fig. 2 é apresentada uma síntese das etapas do presente projeto.



Figura 2 - Síntese das etapas do projeto.

2.1. Sistema de monitoramento

Para a aquisição dos dados de irradiância e de tensão do LDR, foi necessária a concepção de um sistema de monitoramento baseado em IoT que fosse capaz de coletar os dados de um sensor LDR e de um piranômetro. As informações devem ser enviadas para o servidor de aplicação IoT ThingSpeak para que possam ser recuperadas posteriormente para um tratamento e análise.

Neste projeto, é empregado um microcontrolador da série Heltec WiFi LoRa 32 (V2). Essa placa foi especialmente concebida para aplicações relacionadas à IoT, uma vez que reúne um microcontrolador ESP32 com as tecnologias WiFi, LoRa e Bluetooth, todas integradas em um único dispositivo. Além disso, a ESP está equipada com um visor OLED de 0,96 polegadas (Heltec Automation, 2018). No cenário do nosso protótipo, esta placa é responsável por coletar os dados vindos dos sensores, no caso, o piranômetro e o LDR.

A entrada analógica da ESP32 é um recurso importante que permite que a placa leia sinais analógicos, como tensões de sensores e outros dispositivos analógicos. Isso é particularmente útil quando se deseja medir grandezas variáveis de forma contínua, como temperatura, luz ou pressão, que geralmente são representadas por sinais analógicos. A ESP32 possui várias entradas analógicas que podem ser usadas para esse fim, geralmente chamadas de "pinos ADC" (*Analog-to-Digital Converter*, ou Conversor Analógico para Digital). Neste caso é utilizado um ADC de 12 bits, o que significa que é possível representar valores de tensão em um intervalo de 0 a 3,3 V em 4096 etapas discretas, proporcionando uma alta precisão de leitura, uma vez que cada uma dessas etapas corresponde a uma variação de aproximadamente $8,5 \times 10^{-4} V$ (Assis, 2023).

O instrumento utilizado para medir a intensidade da luz solar e gerar os dados de referência que foram utilizados para os modelos de aprendizado de máquina foi o piranômetro do modelo LP02 da marca HUKSEFLUX. Este dispositivo tem a capacidade de medir a irradiância solar, com uma faixa de medição abrangendo valores de 0 a 2000 W/m², sensível a um espectro de luz que varia de 305 a 2800 nm. A tensão gerada pelo sensor é diretamente proporcional à radiação solar, com uma sensibilidade de 18,56 $\mu V/W/m^2$. O piranômetro é capaz de operar em uma ampla faixa de temperatura, de -40 °C até 80 °C, e possui um tempo de resposta de 18 segundos, eliminando a necessidade de alimentação externa (Campbell Scientific, 2013).

O LDR utilizado neste projeto foi o modelo de 5mm que é composto por uma célula de sulfeto de cádmio, que tem sua resistência alterada a depender da intensidade da luz irradiada, onde quanto maior for a intensidade maior a queda em sua resistência, que ocorre de forma logarítmica, este fato dificulta ainda mais a utilização dele como sensor de irradiância solar, porém o objetivo do trabalho é utilizar modelos de inteligência computacional para tentar encontrar uma relação entre a resposta do sensor e a do piranômetro. Geralmente, a resistência do LDR varia de 50 a 12.600 Ω em condições de luz solar, para vários M Ω em situações de escuridão (Hidalgo, 2014).

Implementação do piranômetro. O primeiro dispositivo a ser integrado ao sistema foi o piranômetro, um equipamento de importância crítica, dado seu desempenho robusto e capacidade de abranger uma ampla faixa espectral. Este dispositivo desempenha um papel fundamental ao gerar os dados que servirão como base para a comparação com a resposta do LDR. Entretanto, seu principal desafio reside na baixa amplitude de tensão de saída, que está na ordem de microvolts, tornando inviável uma leitura direta pela ESP32, que é capaz de ler dados de tensão a partir de 800 μV . Portanto, foi necessário incorporar um circuito adicional para amplificar o sinal proveniente do sensor.

Para amplificar o sinal recebido pelo piranômetro foi usado um circuito de amplificação apresentado na Fig. 3. Na instalação do circuito, é utilizado um amplificador operacional do tipo LM324 e dois resistores, de 10 k Ω e de 1 M Ω , resultando em um ganho de 101 vezes, conforme descrito na Eq. (1).

$$G = \frac{R_1 + R_2}{R_1} = \frac{10.000 \Omega + 1.000.000 \Omega}{10.000 \Omega} = 101 \quad (1)$$

Com isso, a variação de 18,56 μV se transforma em 1,874 mV, o que já permite a leitura pelo microcontrolador. Vale salientar que a saída máxima do amplificador é 1,5 V menor que a tensão de entrada, portanto, com uma fonte de alimentação de 5 V, a saída máxima do piranômetro é limitada a 3,5 V. A irradiância máxima que o piranômetro pode captar é de 2000 W/m², o que resulta em uma tensão máxima de saída de 0,03712 V. Após a amplificação pelo circuito, isso se traduz em 3,712 V, superando a tensão máxima que o microcontrolador pode captar, que é de 3,3 V. No entanto,

é importante observar que essa irradiância máxima não é alcançada na região em questão. Portanto, a decisão foi manter o sistema como está, com a compreensão de que a leitura máxima confiável será de 1778 W/m².




Figura 3 - Circuito de amplificação do sinal do piranômetro.

Os dados de tensão obtidos do circuito foram processados e transformados em irradiância por meio do código executado no microcontrolador. Em seguida, esses valores foram agregados durante um período de um minuto e uma média aritmética foi calculada para as leituras realizadas nesse intervalo de tempo. Posteriormente, esses resultados foram transmitidos para o servidor de aplicação do ThingSpeak, cuja função é armazenar os dados para futura disponibilização, permitindo sua posterior análise e tratamento.

Implementação do LDR. Para a instalação do circuito com o LDR, foi medida a resistência do sensor em condições de escuridão e em condições de iluminação para entender sua faixa de resistência em ambos os cenários. Isso nos permitiu escolher um resistor adequado para conectá-lo em série com o LDR, de modo a medir a queda de tensão devido à variação da resistência com a luz. No ambiente escuro, a resistência do sensor estava em torno de 1 MΩ, mas ao ser exposto à luz, essa resistência diminuiu consideravelmente, atingindo valores próximos a 100 Ω (RS Components, 1997). Portanto, optou-se por usar um resistor de 100 Ω, uma vez que a resistência do LDR se aproximou desse valor quando exposto à iluminação. Isso nos levou a esperar que a tensão no resistor seja aproximadamente metade da tensão de entrada quando o LDR estiver em um ambiente iluminado.

Ao instalar o circuito e integrá-lo ao sistema de aquisição de dados, mediu-se a tensão presente no resistor de 100 Ω. Isso se deve ao fato de que a resistência no LDR diminuiu à medida que a intensidade da luz incidente aumenta. Consequentemente, a tensão no LDR diminuiu com o aumento da irradiância, mas essa diminuição se traduz em um aumento da tensão no resistor que está em série com o LDR. Portanto, estabeleceu-se uma correlação direta entre a tensão no resistor e a irradiância. Um esquemático do circuito utilizado para o LDR é apresentado na Fig. 5.

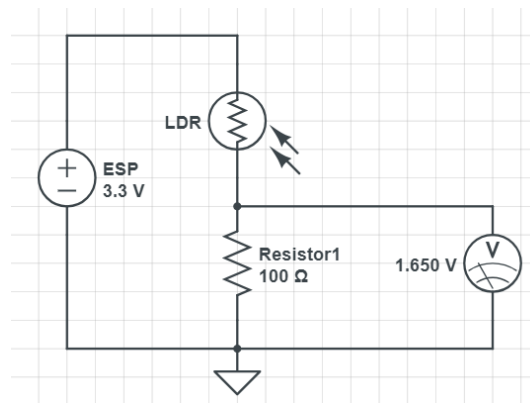


Figura 5 - Representação do circuito do LDR.

Neste caso, o multímetro representa a entrada da ESP que recebe a tensão lida no resistor em série com o LDR. A ESP32 é capaz de ler dados de tensão em uma faixa de 0 a 3,3 V e discretizá-los em valores que variam de 0 a 4095, correspondentes à tensão de entrada. Dessa forma, os valores de tensão provenientes do LDR são continuamente monitorados por meio de uma entrada ADC do microcontrolador, com leituras sendo realizadas a cada segundo. Adicionalmente, a cada minuto, essas leituras são submetidas a uma média aritmética e os resultados são enviados para o servidor do ThingSpeak, permitindo a acumulação dos dados para acesso remoto e análise.

2.2. Modelos de aprendizado de máquina

As tensões de saída do LDR são comparadas com as medições do piranômetro; foi realizado um estudo da correlação entre as medições de ambos os sensores e aplicados modelos de aprendizado de máquina a fim de se obter um modelo de conversão da tensão de saída do LDR em W/m² para medição de irradiância. Os dados obtidos foram tratados em busca de valores atípicos (*outliers*); foi identificado um único valor discrepante que ocorreu na medição de tensão do LDR. Esse caso classificado como *outlier* foi retirado do conjunto de dados utilizado no estudo. Após o pré-processamento dos dados, o conjunto ficou com 12.565 medições, sendo destas 80% destinadas ao treinamento (10.052 medições) e 20% (2.513 medições) destinadas à teste dos modelos de aprendizado de máquina (*machine learning* - ML).

As técnicas computacionais vêm se mostrando uma forma eficaz de otimização do processamento de dados, os modelos são baseados na observação da relação de causa e efeito entre variáveis de entrada e de saída (SANTOS, 2021). No presente estudo, foram aplicadas técnicas de aprendizagem supervisionada de regressão para a modelagem da irradiância em W/m² a partir dos valores de tensão do LDR. Os algoritmos de RP, SVM e RNA são aplicados, detalhados na Tab. 1. Foi definido como preditor a tensão de saída do LDR e os valores de irradiância do piranômetro são atribuídos à variável resposta. É utilizado durante o treinamento dos modelos um esquema de validação aplicando validação cruzada (*Cross-Validation*) *k*-*fold* com cinco 'folds', como forma de prevenção contra *overfitting*.

Tabela 1 - Descrição dos modelos de aprendizado de máquina implementados (MathWorks®, 2023a).

MODELO	TIPO	DEFINIÇÃO
Regressão polinomial	Quadrática	A função contém uma interceptação, termos lineares, interações e termos quadrados.
Support Vector Machine	Fine Gaussian SVM	Modelo SVM que permite variações rápidas na função de resposta. A função kernel é gaussiana com a escala do kernel definida como, onde P é o número de preditores
Rede Neural Artificial	Estreita (<i>Narrow Neural Network</i>)	RNA com uma camada totalmente conectada de tamanho 10, excluindo a camada final totalmente conectada

Separados os dados de treino e teste, definido preditor e variável resposta e escolhida a técnica de validação, as técnicas de RP, SVM e RNA foram aplicadas. Em seguida, os modelos gerados para estimar a irradiação a partir da tensão do LDR são comparados. Para comparação dos dados entre a referência e o preditor pelos modelos desenvolvidos é necessário abordar índices estatísticos. O coeficiente de determinação (R²) é utilizado para estudar o comportamento de duas variáveis, ou seja, mede o grau de associação entre elas e é dado pela Eq. (2) (MathWorks®, 2023b).

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \underline{y})^2}{\sum_{i=1}^n (y_i - \underline{y})^2} \quad (2)$$

Onde \hat{y} é o valor estimado pelo modelo, \underline{y} é o valor médio e y é o valor real.

3. RESULTADOS

Nesta seção são comparadas as medições de dois tipos distintos de sensores utilizados para medição da irradiação: um LDR e um pirômetro. Além disso, são discutidos os resultados obtidos da aplicação de quatro modelos de aprendizado de máquina para correlacionar essas medições. Essa investigação tem como objetivo avaliar a eficácia dos sensores de baixo custo em relação aos modelos de alta precisão, bem como determinar a capacidade dos modelos de aprendizado de máquina em descrever a correlação entre a leitura do LDR e os valores de irradiância. Os resultados apresentados têm implicações no monitoramento de baixo custo de irradiância em aplicações FV, visando uma coleta precisa de dados.

3.1. Análise das medições e correlação do LDR e piranômetro

Por meio do sistema de aquisição de dados desenvolvido, foram medidos dados no período de 19/08/2023 a 08/09/2023, um total de 21 dias. Após a obtenção dos dados brutos vindos do servidor, foi feita uma separação dos dados coletados diariamente. A faixa de irradiância considerada foi de 100 w/m² à 1000 w/m². Posteriormente, foram eliminados os intervalos em que as leituras registraram valores zerados. Observou-se que as leituras do LDR começavam mais cedo do que as do piranômetro, indicando uma alta sensibilidade a níveis de luz baixos. No entanto, dado que o sensor de referência para treinamento e validação dos dados era o piranômetro, as leituras do LDR durante os períodos em que o piranômetro registrava leituras zeradas foram descartadas. Portanto, apenas os valores do LDR que correspondiam a leituras diferentes de zero registradas pelo piranômetro foram mantidos para análise, sendo um total de 12.565 medições. Estas são analisadas e posteriormente aplicadas no desenvolvimento e teste dos modelos.

A comparação das medições dos sensores, LDR e piranômetro, revelou a relação e a aplicabilidade das leituras de tensão do LDR para a determinação da irradiância. Na Fig. 6 é ilustrada a dispersão dos dados coletados por ambos os sensores, com a medida da irradiância pelo piranômetro no eixo x e a medida de tensão do LDR no eixo y. A relação entre essas medidas é não linear, o que justifica a escolha de modelos de regressão não linear para correlacionar os dados.

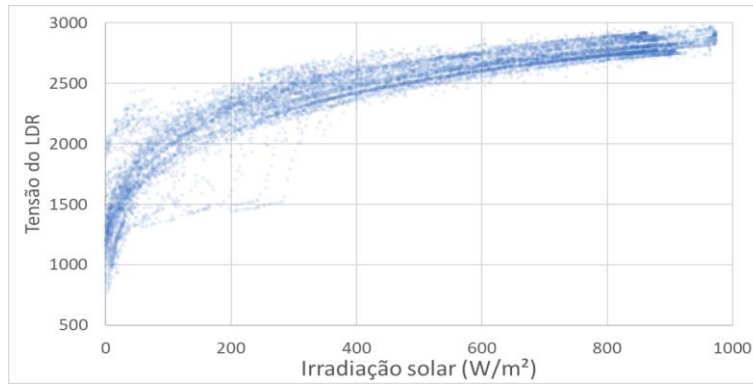


Figura 6 - Gráfico de dispersão da irradiância pela tensão do LDR.

A análise de correlação revelou uma associação entre as leituras de ambos os sensores, com um coeficiente de determinação (R^2) de 0,87, indicando que os dados coletados pelo LDR possuem boa correlação com as medições do piranômetro. Esse resultado sugere que o LDR pode ser uma alternativa viável e de baixo custo para estimar a irradiância com precisão.

A fim de validar a utilidade prática do LDR, a irradiância é monitorada ao longo de três semanas consecutivas. Nas Fig. 7(a), 7(b) e 7(c) são mostrados os registros obtidos por ambos os sensores durante esse período. O LDR segue a curva do pirômetro em todo o período de coleta dos dados, sugerindo sua capacidade de fornecer estimativas precisas da irradiância ao longo do tempo se ajustados os valores por meio de um modelo que correlacione ambos os valores.

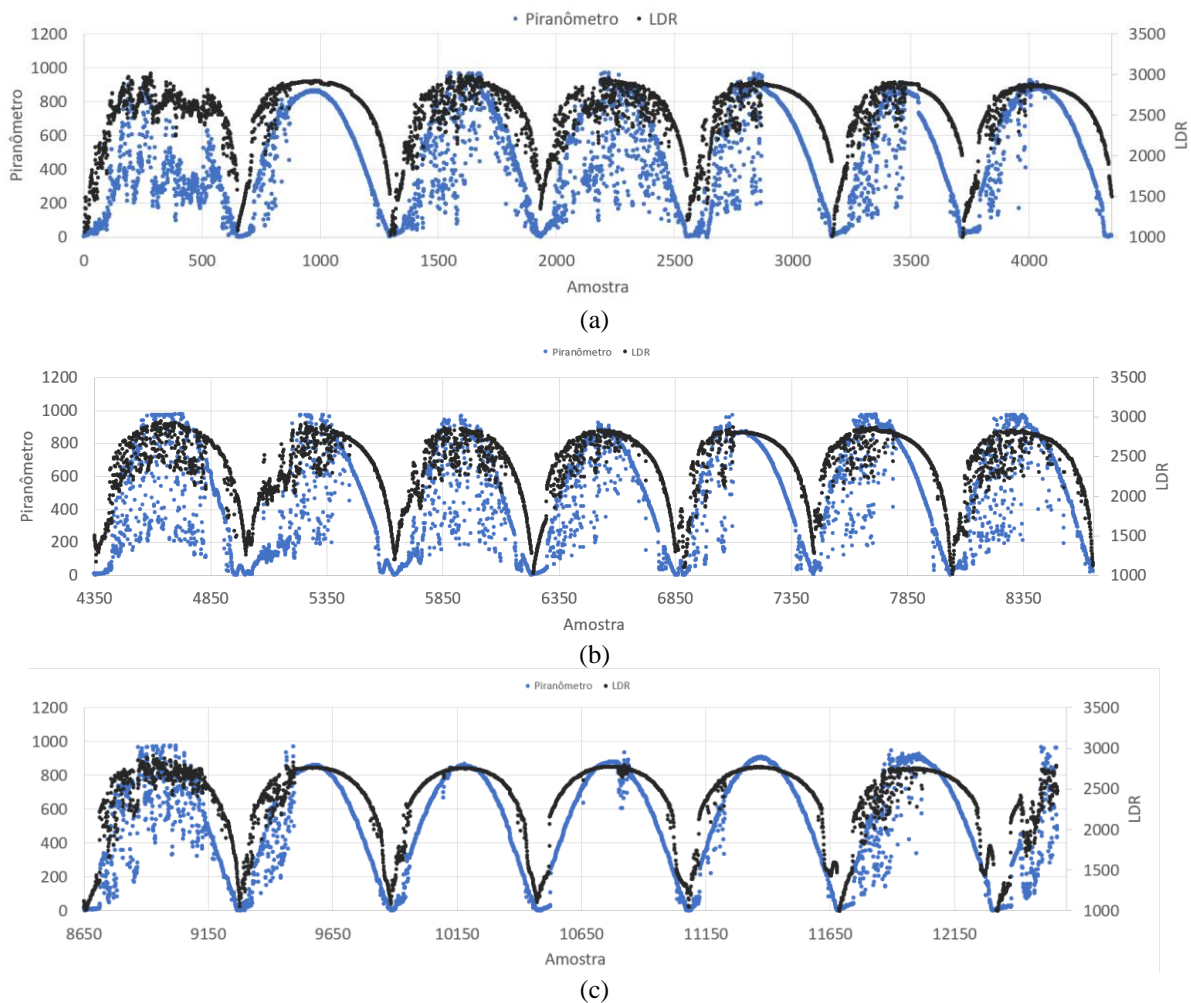


Figura 7 - Medições obtidas pelo LDR e piranômetro durante a: (a) semana 1; (b) semana 2; e (c) semana 3.

Esses resultados demonstram que, mesmo diante da não linearidade observada entre as medições, o LDR pode ser eficaz na descrição da irradiância quando aplicados modelos de regressão não linear adequados. Isso abre possibilidades

promissoras para sua utilização em aplicações práticas de monitoramento FV de precisão, onde a coleta precisa e de baixo custo de dados de irradiância se torna essencial.

3.2. Aplicação dos modelos de aprendizado de máquina

A aplicação de quatro modelos de aprendizado de máquina para correlacionar as medições do LDR com os valores de irradiância revelou aspectos sobre a capacidade desses modelos em descrever a relação entre estes dados. As métricas dos modelos, apresentadas na Tab. 2, demonstram seu desempenho nos dados de treino e teste. Os resultados indicam que todos os modelos apresentaram um bom desempenho, com altos R^2 tanto nos dados de treino quanto nos dados de teste. Entretanto o modelo que apresentou o menor erro médio foi o SVM.

Tabela 2 - Métricas dos modelos.

MODELO	R^2 (TREINO)	R^2 (TESTE)	Erro médio
Regressão polinomial	0,90	0,90	22,48%
SVM	0,92	0,92	18,48%
RNA	0,91	0,92	20,43%

É importante analisar as visualizações gráficas para uma compreensão mais aprofundada. Nas Fig 8(a), 8(b), 8(c) e 8(d) são mostradas as dispersões dos dados de irradiância predita em relação aos dados reais para cada um dos modelos. Embora o modelo de Regressão Polinomial tenha uma métrica R^2 semelhante aos outros modelos, ele apresenta uma dispersão ligeiramente maior em relação à reta diagonal, sugerindo uma menor precisão na predição.




Figura 8 - Gráficos predito vs Real: a) RP; b) SVM; c) RNA.

Nas Fig. 9(a), 9(b) e 9(c) são comparadas as curvas de estimativa e os dados estimados pelos modelos e dos dados de teste. Nestas visualizações, os modelos RNA e SVM estão mais próximos dos dados reais em comparação com a RP, que apresenta um distanciamento maior dos dados reais.




Figura 9 - Gráficos com comparação do estimado e o medido pelos modelos: a) RP; b) SVM; e c) RNA.

Na Fig. 10 são comparados os quatro modelos, incluindo os dados medidos de teste e as estimativas. É possível notar leve vantagem do modelo SVM em relação aos demais, pois sua curva de estimativa se aproxima mais dos dados de teste.




Figura 10 - Comparação entre os dados reais de teste e estimado pelos modelos.

Os resultados demonstram que os modelos de SVM e RNA superam a Regressão Polinomial na capacidade de prever com precisão a irradiância com base nas medições do LDR. Esses modelos apresentaram uma melhor aderência

aos dados de teste, indicando sua utilidade prática na estimativa da irradiância. Dentre os três, o SVM se mostrou melhor na descrição dos dados; apesar de não apresentar vantagem em relação às métricas do modelo RNA (ambos com R^2 de 0,92), ele apresenta outras vantagens como menor complexidade e rapidez no tempo de treinamento.

4. CONCLUSÃO

A análise das medições realizadas tanto pelo LDR quanto pelo piranômetro revela uma correlação não linear entre esses sensores, evidenciada por um coeficiente de determinação de 0,87. A aplicação de três modelos de aprendizado de máquina - regressão polinomial, SVM e RNA - para correlacionar as medições do LDR com os valores de irradiação demonstra um bom desempenho geral, com coeficientes de determinação altos, alcançando 0,90 para a RP e 0,92 para os demais modelos nos dados de teste. O erro médio para a RP foi calculado em 22,48%, enquanto o SVM apresentou 18,48% e o RNA, 20,92%. Embora os resultados indiquem que o LDR, quando acompanhado por modelos de aprendizado de máquina adequados, pode ser uma alternativa econômica para a medição da irradiação, é importante ressaltar que este sensor pode não ser o mais adequado para essa aplicação considerando-se o erro médio significativo observado nos testes. Além disso, a faixa espectral que ele é capaz de captar é muito estreita. As análises sugerem que os modelos SVM e RNA possuem uma melhor aderência aos dados reais em comparação com a Regressão Polinomial. Embora o SVM tenha se destacado na descrição dos dados, não houve uma vantagem significativa em relação às métricas do modelo RNA (ambos com R^2 de 0,92). Ademais, o SVM possui outras vantagens, como menor complexidade, rapidez no tempo de treinamento e erro médio mais baixo. No entanto, é importante salientar que os resultados indicam a presença de imprecisões, ressaltando a necessidade de avaliações adicionais. Além disso, é relevante observar que a influência da temperatura não foi considerada neste processo, o que sugere a necessidade de investigações mais aprofundadas para uma compreensão mais completa do uso do LDR para este propósito.

Agradecimentos

O segundo autor agradece à Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) nos termos da Instrução Normativa N° 04/2019 pela bolsa de doutorado. O terceiro autor agradece à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 pela bolsa de doutorado. O quinto autor agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade em pesquisa.

REFERÊNCIAS

- Assis, D. P. de. Desenvolvimento de um sistema de monitoramento com rede LoRa aplicado a uma planta fotovoltaica. Trabalho de Conclusão de Curso (Graduação em Engenharia de Telecomunicações) - Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia de Teleinformática, Fortaleza, 2023.
- Barros, R. C. de *et al.* Low-Cost Solar Irradiance Meter using LDR Sensors. In: 13th IEEE International Conference on Industry Applications, 2018, Belo Horizonte: CEFET - MG, 2018.
- Bastos, M. F. Desenvolvimento de um dispositivo para monitoramento de painéis fotovoltaicos. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal Rural do Semi-Árido, Mossoró, 2019.
- Campbell Scientific. LP02 Huskflux Pyranometer. Logan, UT, 2013. Acessado em: 07 maio 2023. Disponível em: <<https://s.campbellsci.com/documents/cr/manuals/lp02.pdf>>.
- Heltec Automation. WiFi LoRa 32 (V2). 2018. Disponível em: <<https://heltec.org/project/wifi-lora-32/>>. Acesso em: 02 fev. 2021.
- Hidalgo, F. G.; Martinez, R. F.; Vidal, E. F. Design of a low-cost sensor for solar irradiance, 2014. Disponível em: <https://studylib.net/doc/18203756/design-of-a-low-cost-sensor-for-solar-irradiance>. Acesso em 4 de outubro, 2023.
- MathWorks®. Choose Regression Model Options. 2023a. Disponível em: <<https://nl.mathworks.com/help/stats/choose-regression-model-options.html>>. Acesso em: 4 set. 2023.
- MathWorks®. Coefficient of Determination (R-Squared). 2023b. Disponível em: <<https://nl.mathworks.com/help/stats/coefficient-of-determination-r-squared.html>>. Acesso em: 4 set. 2023.
- Santos, L. O. Uso de Aprendizado de Máquina no Desenvolvimento de Modelos de Previsão da Temperatura de Operação de Células Fotovoltaicas, dissertação (Mestrado Acadêmico em Engenharia Mecânica) - Programa de Pós-Graduação em Engenharia Mecânica do Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, Brasil, 2021.
- Pereira, R. I. S. e. a. Integração de sistemas de monitoramento iot em rede aplicados em plantas de microgeração fotovoltaica. Seminário Nacional de Produção e Transmissão de Energia Elétrica, 2019.
- RS Components. Light dependent resistor, NORP12 RS stock number 651-507 Datasheet, 1997. Disponível em: https://components101.com/sites/default/files/component_datasheet/LDR%20Datasheet.pdf. Acesso em: 4 de outubro de 2023.
- Vieira, R. G. *et al.* Medição de radiação solar global utilizando sensor LDR. Revista de Engenharia e Tecnologia, ISSN 2176-7270, 2015.

PROPOSAL FOR A SOLAR IRRADIANCE MONITORING SYSTEM WITH LDR

Abstract. *The study proposes the use of Light Dependent Resistors (LDRs) as a cost-effective and efficient alternative to pyranometers. It presents proposals for a model capable of converting values measured by LDR into solar irradiance data. The research describes the development of an Internet of Things-based monitoring system using the ThingSpeak platform. In this system, analog voltage signals from the LDR, which varies its resistivity according to luminosity, are captured and sent to the server for comparison with values measured by the pyranometer (W/m^2). Data from both devices were collected over three weeks, limited to the daily operating interval of the pyranometer. In an initial analysis, the correlation between readings revealed a coefficient of determination (R^2) of 0.87, demonstrating the existing correlation between LDR and pyranometer measurements. However, it is noteworthy that the LDR is not the most suitable for solar irradiance measurements but was employed here to evaluate the performance of machine learning methods. Thus, 12,565 measurements were obtained, with 80% used for training and 20% for testing the applied models, including Polynomial Regression (PR), Support Vector Machine (SVM), and Artificial Neural Network (ANN). Results indicate that SVM and ANN achieved an R^2 of 0.92 in testing, surpassing PR, which reached 0.9 in predicting solar irradiance based on LDR. SVM stood out due to its lower complexity and faster training time. However, upon analyzing the mean error between pyranometer measurements and those predicted by the models, it was observed that PR had an error of 22.48%, SVM registered 18.48%, and ANN showed an error of 20.43%, confirming that this sensor is not the most suitable for this purpose.*

Keywords: *Photovoltaic Monitoring, Solar Irradiance, Low Cost Monitoring.*