

Desarrollo de un algoritmo para estimar las corrientes de cortocircuito de un panel
fotovoltaico mediante procesamiento de imágenes.

Diego Fernando Mejía Pinto

Trabajo de Grado para Optar el título de Ingeniero Electrónico

Director

Juan David Bastidas Rodríguez

Doctor en ingeniería con énfasis en ingeniería eléctrica y electrónica.

Codirector

Fabio Martínez Carillo

Doctor en ingeniería de sistemas y computación.

Universidad Industrial de Santander

Facultad de Ingenierías Físico-Mecánicas

Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones

Bucaramanga

2019

Dedicatoria

Agradezco a Dios por la vida y las oportunidades que me ha brindado, así mismo, por todas las bendiciones recibidas hasta este punto.

A mis padres Raúl Arturo Mejía y Luz Marlesvi Pinto quienes han dado lo mejor de sí mismos para que yo sea quién soy hoy. Por enseñarme valores y darme fortaleza en los momentos difíciles; por acompañarme en el camino.

A la profesora Silvia Susana por ser un apoyo emocional, por sus consejos y desearme siempre lo mejor.

Agradezco también a toda mi familia y amigos quienes me han brindado acompañamiento a lo largo de la vida, especialmente durante el desarrollo de mi carrera.

«No te rindas, aún estás a tiempo de abrazar la vida y comenzar de nuevo, aceptar tu sombra, liberar el peso y retomar el vuelo.

No te rindas, que la vida es eso, continuar el viaje, perseguir los sueños, abrir las esclusas, destrabar el tiempo, correr los escombros y destapar el cielo.

No te rindas, por favor, no cedas. »

-Mario Benedetti

Agradecimientos

Un agradecimiento especial a los profesores Juan David Bastidas Rodríguez y Fabio Martínez Carrillo por su guía y colaboración. A las escuelas de Física e Ingenierías Eléctrica, Electrónica y Telecomunicaciones por los equipos y espacios suministrados para la realización del trabajo.

Tabla de Contenido

	Pág.
INTRODUCCIÓN	16
1. OBJETIVOS	20
1.1 Objetivo General	20
1.2 Objetivos Específicos.....	20
2. GENERALIDADES	21
2.1 Modelo un módulo fotovoltaico (PV).....	21
2.2 Modelo un panel PV	23
2.3 Modelos de Color.....	24
2.4 Aprendizaje de Máquina	24
3. MÉTODO PROPUESTO.....	28
4. METODOLOGÍA	29
4.1 Recolección de Datos.....	29
4.2 Procesamiento de Datos	30
4.2.1 Procesamiento de Curvas.....	30
4.2.2 Procesamiento de Imágenes.....	34
4.3 Entrenamiento	40
4.3.1 Selección de Método y Espacio de Color.	40
4.3.2 Desarrollo del entrenamiento.....	41
4.4 Uso del Algoritmo.....	43
5. RESULTADOS.....	45
5.1 Resultados selección de método de aprendizaje y espacio de color	45

5.2 Resultados del entrenamiento.	45
5.3 Resultados del Algoritmo	46
6. CONCLUSIÓN.....	48
REFERENCIAS BIBLIOGRÁFICAS.....	50
APÉNDICES.....	52

Lista de Tablas

Tabla 1. Resultados para imágenes de un panel PV con Iph promedio asociada.	45
--	----

Lista de Figuras

	Pág.
Figura 1. Modelo circuital de un módulo PV.	21
Figura 2. Curvas características de un módulo del panel PV	22
Figura 3. Curvas I-V para módulos con diferente nivel de irradiancia.....	22
Figura 4. Representación del modelo de un panel PV.....	23
Figura 5. Esquema del método propuesto.....	28
Figura 6. Esquema Algoritmo de Estimación de I_{ph}	29
Figura 7. Recolección de Datos.	30
Figura 8. Curvas características I-V.....	31
Figura 9. Curva característica I-V en condiciones de sombreado parcial.....	33
Figura 10. Derivada con Umbral para detección de I_{ph}	33
Figura 11. Captura recortada del panel fotovoltaico.....	34
Figura 12. Algoritmo de procesamiento de imágenes para el entrenamiento.....	35
Figura 13. Módulos segmentados a partir de ecuaciones de recta.	36
Figura 14. Pseudocódigo para la segmentación de módulos.	36
Figura 15. Resultado de la segmentación de módulos.....	37
Figura 16. Proceso de Vectorización de matrices representativas de cada módulo.....	38
Figura 17. Ilustración método de asociación de I_{ph}	39
Figura 18. Desglose de matriz de entrenamiento.....	41
Figura 19. Procedimiento en Python.....	42
Figura 20. Esquema de funcionamiento del Algoritmo Final.....	43
Figura 21. Resultados del entrenamiento de los modelos.....	46

Figura 22. Resultados en la estimación de corrientes por módulo.	47
---	----

Lista de Apéndices

	Pág.
A. Hoja de datos panel PV utilizado.....	52
B. Error relativo entre corrientes conocidas y corrientes estimadas.....	53

Resumen en Español

TÍTULO: DESARROLLO DE UN ALGORITMO PARA ESTIMAR LAS CORRIENTES DE CORTOCIRCUITO DE UN PANEL FOTOVOLTAICO MEDIANTE EL PROCESAMIENTO DE IMÁGENES.*

AUTOR: DIEGO FERNANDO MEJÍA PINTO.**

PALABRAS CLAVE: PROCESAMIENTO DE IMÁGENES, PANELES FOTOVOLTAICOS, IRRADIANCIA, CORRIENTES DE CORTOCIRCUITO, EFICIENCIA ENERGÉTICA, ENERGÍAS LIMPIAS, APRENDIZAJE DE MÁQUINA.

DESCRIPCIÓN:

A raíz del cambio climático las energías renovables han tomado gran relevancia para hacer frente a esta problemática. Entre las más popularizadas se encuentra la energía fotovoltaica debido a sus costos y eficiencia, sin embargo en este aspecto aún hay mejoras que realizar. La eficiencia energética de un panel PV se puede mejorar a partir del seguimiento del punto de máxima potencia (MPP). Sin embargo, el comportamiento del panel se ve afectado cuando opera en condiciones de sombreado parcial, produciendo múltiples MPPs. La presencia de máximos locales puede ocasionar que los sistemas de MPPT no ubiquen el máximo global, disminuyendo la potencia que se puede extraer del panel fotovoltaico.

El propósito de este trabajo es aportar a la optimización de la energía fotovoltaica en términos del procesamiento de imágenes, minimizando la disrupción en la operación del panel PV al desarrollar un algoritmo basado en IA, capaz de estimar las corrientes de cortocircuito de un panel fotovoltaico, de manera que puedan ser usadas para alimentar modelos matemáticos propuestos

* Trabajo de Grado

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones. Director: PhD. Juan David Bastidas. Ingeniero Electrónico.

en diversos estudios para que estos ayuden a mejorar la ubicación del MPP al poder acotar la región en la que se encuentra el punto de máxima potencia global.

Se recolectaron imágenes del panel fotovoltaico usando una cámara óptica y también se generaron barridos en tensión versus corriente haciendo uso de una carga electrónica programable. Se usaron descriptores de luminancia para entrenar los modelos de estimación basados en el método de árbol de decisión. Los resultados obtenidos en la estimación de corrientes, a partir de los modelos entrenados, mostraron bajo índice de error y una relación lineal con los datos conocidos. Como ventajas se tiene la facilidad de implementación, precisión y bajos costos.

Resumen en Inglés

TITLE: DEVELOPMENT OF AN ALGORITHM TO ESTIMATE THE SHORT-CIRCUIT CURRENTS OF A PHOTOVOLTAIC PANEL IN MEANS OF PROCESSING IMAGES.*

AUTHOR: DIEGO FERNANDO MEJÍA PINTO.**

KEYWORDS: IMAGES PROCESSING, PHOTOVOLTAIC PANELS, IRRADIANCE, SHORT-CIRCUIT CURRENTS, ENERGY EFFICIENCY, CLEAN ENERGIES, MACHINE LEARNING.

DESCRIPTION:

Due to the climatic change the renewal energies has taken a huge relevance to treat this problem. The most popularized has been the photovoltaic energy because its low cost and efficiency but in this kind of energy there are still some topics to improve. The energy efficiency of a PV Panel could be improved by tracking its maximum power point (MPP). However, the behaviour of the panel is affected when it works under partial shadow conditions, this generates multiple MPPs. The presence of local maxima could make MPPT systems does not find the global maxima reducing power obtainance. For this reason the purpose of this paper is help to photovoltaic energy optimization in means of images processing minimizing disruption in the operation of PV panels. For this an algorithm is developed based on IA taking advantage of machine learning. It is able to estimate the short-circuit currents in order to use them as entries of mathematics models proposed in several researches in order to improve the localization of MPP by the definition of a region in which could be the global maxima.

For this purpose data was collected using an three megapixels optic camera for the images of the photovoltaic panel and an electronic programmable load to generate a voltage swipe for the

* Degree Project

** Faculty of Physics Mechanics. Engineering Electrical, Electronic and Telecommunications School. Director: PhD. Juan David Bastidas Rodriguez. Electronical Engineer.

current vs voltage curve. Then the I-V data were processed in order to extract the short-circuit currents. Luminance descriptors of the image were used as features to train estimation models based on decision tree method. The trained models were implemented in the final algorithm. The obtained results in estimation of currents shown a low error index and a linear relation with known data which indicates models were correctly trained and the proposed method works for this application. The advantage of this proposed method is an easier implementation, good precision and low cost of maintenance.

Introducción

En la actualidad debido al cambio climático producido, en parte, por el impacto ambiental que tiene la generación de energía eléctrica a partir de combustibles fósiles, se ha hecho necesario investigar alternativas de generación más ecológicas. Entre éstas podemos encontrar una de las más importantes: La energía solar. Existen dos formas de generar electricidad a partir de la radiación solar. La primera de ellas es convertir la energía del sol en calor (Energía térmica solar). La segunda opción es tomar la radiación y convertirla en corriente mediante materiales fotoeléctricos (Energía fotovoltaica).

Para el fin anteriormente mencionado, se recurre a la implementación de sistemas fotovoltaicos (PV). Los sistemas PV se encuentran conformados por elementos llamados generadores PV, cuya estructura se compone por celdas, que a su vez componen módulos (unidades básicas de los arreglos fotovoltaicos), constituyendo de esta manera lo que denominamos un panel PV. Es importante tener en cuenta que cada módulo del panel PV se encuentra equipado con un diodo de bypass como dispositivo de protección eléctrica.

En este novedoso campo de las energías limpias es importante estar en constante avance tecnológico para aprovechar al máximo la energía que se obtiene a partir de los recursos primarios. Este es el caso de la energía fotovoltaica, la cual ha tenido una rápida y constante evolución durante las últimas décadas debido a su importancia; facilidad de implementación, eficiencia y costos. Sin embargo, aún se necesita realizar mejoras para garantizar una eficiencia energética superior a la actual.

En un panel PV existen variables básicas que permiten conocer su rendimiento en cuanto a una generación de energía, entre ellas se encuentran: la temperatura y la irradiancia. La temperatura

del panel se puede estimar fácilmente a partir de la temperatura ambiente, pero la irradiancia es más difícil de medir. La dificultad que se tiene al medir la irradiancia se debe principalmente a los instrumentos que la miden. Para realizar la medición se emplea un sensor llamado piranómetro. Este sensor es capaz de medir la irradiancia en un punto, no obstante, la irradiancia puede variar de manera casi continua sobre el área que comprende el panel. Debido a esta característica del sensor, puede presentarse el caso de experimentar condiciones de sombra sobre el panel pero no sobre el sensor, el resultado es entonces una lectura de irradiancia errónea. Como es lógico pensar, poner una red de sensores de irradiancia sobre todo el panel, como se menciona en (Rabinovici & Dagan, 2012), es ineficiente, el motivo es explicado más adelante. Por otra parte, la irradiancia es proporcional a un parámetro característico de los módulos llamado corriente de cortocircuito (I_{sc}) o como veremos más adelante, I_{ph} . Saber esto es de gran ayuda, pues conocer la irradiancia, o análogamente, las corrientes de cortocircuito permite una mejor aproximación al punto de máxima potencia (MPP) (Accarino, Petrone, Ramos-Paja, & Spagnuolo, 2013).

La ubicación del MPP se ha planteado como solución para aprovechar al máximo la obtención de energía eléctrica a partir de la radiación solar. Para ello se implementa un sistema electrónico de seguimiento de punto de máxima potencia (MPPT).

Una característica de los sistemas tradicionales empleados para el MPPT es que cuando el panel PV opera en condiciones de sombreado parcial, el MPPT podría ubicar un MPP local y no un MPP global debido a la influencia que tiene la sombra sobre los sistemas fotovoltaicos (Díaz-Dorado, Suárez-García, Carrillo, & Cidrás, 2010), (Xu, Song, Bian, Yukita, & Ichiyanagi, 2010). Esto implica que no se aprovecha la máxima potencia que puede entregar el panel fotovoltaico y por lo tanto se hace necesario implementar un método para resolver esta desventaja.

Algunos artículos tratan de abordar esta problemática mediante la implementación de grandes redes de sensores de irradiancia (Kuszamaul, Ellis, Stein, & Johnson, 2010), (Kern & Russell, 2003), que resultan ser poco eficientes debido a que solo puede estimar irradiancia de una manera discreta, además de los elevados costos que supone construir y mantener una red de sensores de este tipo. Otros métodos propuestos logran detectar máximos globales en presencia de máximos locales (Patel & Agarwal, 2008) pero requieren realizar análisis bastante disruptivos en la operación del panel PV. También se ha recurrido a la configuración de arreglos PV, a través de controladores basados en el procesamiento de imágenes, en el que se identifica en qué módulo está incidiendo la sombra, para obtener la máxima potencia del panel PV (Patnaik, Aswani, Sarkar, & Duttagupta, 2014).

En (Rabinovici & Dagan, 2012) se logra desarrollar un método que crea mapas de irradiancia de paneles PV a partir del procesamiento de video; como se mencionó anteriormente, la irradiancia es un parámetro que permite mejorar el MPPT. No obstante, el propósito de usar la irradiancia es alimentar modelos propuestos en (Rabinovici & Frechter, 2010) que permitan aproximar numéricamente las corrientes de cortocircuito a partir del cálculo de la temperatura de los módulos. En consecuencia, el presente trabajo toma importancia en cuanto a que permite estimar las corrientes I_{ph} como una aproximación válida de las corrientes de cortocircuito de forma directa a partir del procesamiento de imágenes al hacer uso de descriptores de luminancia. Esto simplificaría, en gran medida, los cálculos desarrollados en (Rabinovici & Frechter, 2010).

El método propuesto en esta investigación aborda la problemática desde el procesamiento digital de imágenes y aprendizaje de máquina para desarrollar un algoritmo que permita estimar de manera directa, las corrientes de cortocircuito de un panel PV, pues a partir de ellas es posible alimentar modelos matemáticos que permiten mejorar la estimación de la ubicación del MPP en

presencia de máximos locales, sin ser disruptivo en la operación del panel fotovoltaico; haciendo de esta implementación novedosa e importante debido a su bajo costo de implementación y efectividad, permitiendo aportar al desarrollo de nuevas tecnologías y optimizar el aprovechamiento de la energía solar.

1. Objetivos

1.1 Objetivo General

Desarrollar un algoritmo que permita estimar las corrientes de cortocircuito de un panel fotovoltaico a partir del procesamiento digital de imágenes capturadas con una cámara óptica.

1.2 Objetivos Específicos

1.2.1 Capturar imágenes del panel fotovoltaico en diferentes instantes del día ante distintas condiciones de sombra controlada durante varios días, asociando a cada imagen, los datos de corrientes fotovoltaicas (I_{ph}) obtenidos a partir de los puntos de inflexión de las curvas de corriente versus tensión generadas previamente a las capturas de las imágenes.

1.2.2 Procesar las imágenes capturadas; llevándolas al espacio de color YCbCr e implementar algoritmos que permitan la segmentación semi-automática de los módulos del panel y adecuación de datos de las imágenes, necesarios para el posterior entrenamiento del sistema de estimación de corrientes de cortocircuito.

1.2.3 Realizar el entrenamiento de un sistema de estimación de corrientes de cortocircuito de los módulos mediante aprendizaje de máquina a partir de una base de datos (Dataset) creada con las imágenes del panel fotovoltaico previamente seleccionadas y procesadas digitalmente.

1.2.4 Comprobar la efectividad del algoritmo, obteniendo los valores de las corrientes fotovoltaicas estimadas por el algoritmo, usando como entrada parte del conjunto de imágenes de la base de datos de prueba y comparando dicho resultado con los valores obtenidos para las corrientes de cortocircuito extraídas de los puntos de inflexión de las gráficas de corriente versus tensión generadas de manera experimental con la carga electrónica programable.

2. Generalidades

2.1 Modelo un módulo fotovoltaico (PV)

El modelo circuital de un módulo es mostrado en la figura 1. Un parámetro importante en este modelo es la corriente I_{ph} , que depende de la temperatura, la irradiancia, el material y el área del módulo.




Figura 1. Modelo circuital de un módulo PV. Adaptado de (Accarino et al., 2013)

En condiciones ideales la corriente I_{ph} es aproximadamente la corriente de cortocircuito (I_{sc}) del panel PV (Accarino et al., 2013). Esto puede entenderse fácilmente teniendo en cuenta que la resistencia R_p , usada en simulaciones de sombreado parcial, suele ser mucho más grande que R_s y que la corriente I_d es significativamente menor que la corriente I_{ph} . A partir de esto es válido plantear la siguiente ecuación que permite usar la corriente I_{ph} como una aproximación muy cercana a la corriente de cortocircuito del módulo (Accarino et al., 2013).

$$I_{ph} = I_{sc} \quad (1)$$

Para un módulo, las curvas características I-V y P-V varían en magnitud de acuerdo a la irradiancia incidente sobre él. Ver figura 2. La zona plana en azul es la corriente I_{ph} del módulo.




Figura 2. Curvas características de un módulo del panel PV

Sin embargo, cuando el panel PV se ve afectado por mediciones de sombreado parcial, las corrientes I_{ph} de cada módulo difieren entre sí. Esto es debido al nivel de irradiancia que afecta cada módulo. Ver figura 3.




Figura 3. Curvas I-V para módulos con diferente nivel de irradiancia.

En la Ecuación 2 se detalla la relación existente entre la corriente I_{ph} y la irradiancia G .

$$I_{PH} = \frac{G}{G_{stc}} (I_{SC_{stc}} + \alpha_{Isc} (T - T_{stc})) \quad (2)$$

2.2 Modelo un panel PV

Generalmente los módulos de un panel PV se encuentran configurados en serie, por lo que el modelo que representa al panel depende de la cantidad de módulos que posea. El panel empleado en este trabajo posee tres módulos y puede ser representado de la siguiente manera.




Figura 4. Representación del modelo de un panel PV.

La curva I-V de un panel está conformada por las curvas de los módulos, estas se suman en tensión, por tratarse de una conexión en serie. Como se explicó anteriormente, en condiciones de sombra se producen diferentes corrientes fotoeléctricas entre los módulos que componen el panel. La diferencia entre las I_{ph} de cada módulo produce que se generen múltiples picos de máxima potencia (ver Figura 5). Estas corrientes se pueden hallar al realizar un escaneo de la curva característica para detectar puntos de inflexión, también pueden ser estimadas al analizar las características P-V del panel, no obstante, durante la operación normal de un panel fotovoltaico esto resulta ser un método disruptivo para su funcionamiento.

Por lo anterior, el método que se propuso en esta investigación buscaba obtener las corrientes I_{ph} de cada módulo, de manera directa, mediante el procesamiento de imágenes de forma

inteligente a través del aprendizaje de máquina. Conocer las corrientes de cortocircuito de los módulos significa una ayuda para los sistemas de MPPT en la aproximación del MPP global en presencia de máximos locales.

2.3 Modelos de Color

Un modelo de color es un conjunto de expresiones matemáticas que permiten representar los colores mediante números y/o posiciones en un sistema de referencia. La representación de un conjunto de colores mapeados a través de un modelo de color, originan un espacio de color. Frecuentemente se refiere de manera indistinta a estos dos conceptos. Se presenta el modelo de color YCbCr debido a que fue el seleccionado para realizar el entrenamiento en el desarrollo de esta investigación.

El modelo de color para llevar a los colores del espacio RGB al YCbCr es el siguiente:

$$\text{RGB} \rightarrow \text{YCbCr} \begin{cases} Y = K_R \times R' + (1 - K_R - K_B) \times G' + K_B \times B' \\ C_B = \frac{1}{2} \times \frac{B' - Y'}{1 - K_B} \\ C_R = \frac{1}{2} \times \frac{R' - Y'}{1 - K_R} \end{cases} \quad (3)$$

Los valores RGB son normalizados de 0 a 1, las constantes K ya están definidas y con ajuste gamma.

2.4 Aprendizaje de Máquina

El aprendizaje de máquina es una rama de la inteligencia artificial, enfocada en desarrollar algoritmos que permitan resolver problemas de reconocimiento, clasificación y regresión de

patrones. Existen diferentes métodos de aprendizaje, se suelen clasificar entre métodos supervisados y no supervisados.

2.4.1 Métodos supervisados. Los métodos supervisados se caracterizan por aprender a predecir valores al relacionar un conjunto de entradas X a salidas Y . A esta relación se le llama etiquetas y el conjunto de entrenamiento se denota como $D = \{(X_i, Y_i)\}_{i=1}^N$ donde N es el número de datos usados para el entrenamiento.

Dentro de estos métodos encontramos:

- Máquinas de Soporte Vectorial (SVM)
- K – Vecinos
- Árboles de Decisión
- Regresión Logística
- Redes Neuronales
- Clasificador Bayesiano

Estos métodos son usados con frecuencia en problemas de clasificación y regresión.

2.4.2 Métodos no supervisados. Los métodos no supervisados, a diferencia de los supervisados, no requieren relacionar los datos, están diseñados para encontrar patrones en los datos de entrada X , generalmente se usan en compresión de archivos. El conjunto de entrenamiento se denota como $D = \{(X_i)\}_{i=1}^N$

Dentro de algunos de ellos se encuentran:

- K – Means

- Mezclas Gaussianas
- Agrupamientos Jerárquicos
- Mapas Auto-Organizados

2.4.3 Árbol de decisión. Es un algoritmo de aprendizaje supervisado, de fácil interpretación empleado en aplicaciones informáticas que requieren inteligencia artificial para establecer modelos de predicción. A nivel estructural, un árbol de decisión es un conjunto de vértices y aristas denotado como $DT(V,G)$, que representan los instantes y caminos de decisión.

2.4.3.1 Estructura y terminología. Los siguientes son algunos términos relacionados a la estructura de un árbol de decisión.

- **Población o Muestra:** Define el punto de inicio de dónde parte el algoritmo para originar las divisiones.
- **Vértices:** Son los puntos en los que se establecen umbrales de decisión. Constituyen los nodos del árbol.
- **Aristas:** Son los caminos que llevan a diferentes vértices una vez se ha tomado una decisión a partir del umbral. Constituyen los nodos de decisión y se representan gráficamente como flechas.
- **Niveles/Sub-árboles:** Dependiendo de la cantidad de vértices existentes, se conformaran niveles más internos de decisión que pueden agruparse en árboles internos.
- **Nodos terminales:** Extremo final del árbol de decisión dónde se da respuesta al estímulo de entrada.

De acuerdo al problema de aprendizaje, se pueden establecer árboles de regresión y árboles de clasificación. Se diferencian principalmente por el tipo de variable que estiman, en el caso de los árboles de clasificación, la variable estimada es categórica y en los de regresión es cuantitativa.

2.4.3.2 Criterio de Ramificación. Las ramificaciones se producen en los vértices, como se mencionó anteriormente, en estos puntos existen umbrales de decisión que son los que originan las ramificaciones o aristas. La manera en que se establecen los umbrales de decisión está dada por algoritmos de minimización específicos para cada tipo de árbol. Dentro de los algoritmos de selección de umbral están: Chi Cuadrado, índice de Gini, ganancia de información y reducción de la varianza.

Este último es un algoritmo empleado para problemas de regresión, es decir, cuya variable de interés es cuantitativa-continua. El algoritmo usa la fórmula típica de la varianza.

$$Var = \frac{\sum (X - \bar{X})^2}{n} \quad (4)$$

Se debe calcular la varianza de cada nodo para posteriormente calcular la varianza de cada arista o división. Ésta es calculada como el promedio ponderado de las varianzas de cada nodo. Finalmente se debe escoger la división con la varianza más pequeña para seleccionar el umbral y dividir la población.

Existen diversos algoritmos que se implementan para realizar procesos de aprendizaje con el método de Árbol de Decisión, entre ellos están: ID3, CART, C4.5, C5.0, CHAID. Es importante resaltar que este método tiene buenos resultados en dónde la relación entre la variable

independiente y dependiente es compleja y altamente no lineal. En problemas lineales, es conveniente usar los métodos tradicionales de regresión.

El enfoque tomado para abordar el problema que busca resolver éste artículo es un enfoque de aprendizaje supervisado de regresión no paramétrico. Supervisado pues se realiza el aprendizaje a partir de entradas X y salidas Y conocidas, no paramétrico debido a que el comportamiento de los datos de Iph de cada módulo no puede ser supuesto como una función conocida que lo represente pues tienen un comportamiento no lineal. Finalmente de regresión ya que el resultado de la estimación es cuantitativo.

3. Método Propuesto




Figura 5. Esquema del método propuesto.

El esquema general del método propuesto es mostrado en la figura 5. La captura de imagen es realizada por una cámara óptica de 3 MP. Posteriormente la imagen es procesada por el algoritmo que es el resultado de un procesamiento de curvas I-V e imágenes, así como también del aprendizaje de máquina. Finalmente el algoritmo permite estimar las corrientes de cortocircuito de cada uno de los módulos.




Figura 6. Esquema Algoritmo de Estimación de Iph.

El funcionamiento general del algoritmo desarrollado es mostrado en la figura 6. La imagen capturada es enviada como entrada del algoritmo. Se realiza la segmentación de los módulos, posteriormente cada imagen de módulo segmentada es procesada para extraer los datos que los modelos de entrenamiento son capaces de reconocer, dando como resultado la estimación de las corrientes de cortocircuito de cada uno de los módulos del panel.

En secciones posteriores se explica con más detalle el procesamiento al que fueron sometidas las imágenes.

4. Metodología

4.1 Recolección de Datos

Se generaron curvas características I-V del panel PV utilizando una carga electrónica programable BK PRECISION 8500, se usó MATLAB para realizar la programación de la carga y el algoritmo de procesamiento de datos de curvas I-V. Las curvas fueron generadas en diferentes instantes del día, de manera que el panel PV experimentara condiciones variadas de luminosidad y sombra. Se trabajó de manera controlada con la sombra. Fue proyectada por un muro adyacente al panel en horas de la tarde, de esta forma, se evitó la generación de ruido provocado por el movimiento de la sombra al proyectarla de manera manual al sostener un objeto.

Tras realizar el barrido en tensión, para obtener las curvas I-V, se capturó una imagen por cada curva, de manera que existiera una correspondencia entre imagen y curva I-V. Se tuvo en cuenta la hora de creación de los archivos para la asociación de imagen-datos, ver figura 7. El objetivo de esta etapa fue crear una base de datos lo suficientemente confiable para poder entrenar el sistema de reconocimiento de imagen y estimación de Iphs.




Figura 7. Recolección de Datos.

4.2 Procesamiento de Datos

4.2.1 Procesamiento de Curvas. En la figura 8 se muestra la representación de dos curvas características de corriente versus tensión. En azul se muestra una curva en condiciones ideales de luminosidad, mientras que en naranja, la curva resultante al experimentar condiciones de sombreado parcial en los módulos del panel.




Figura 8. Curvas características I-V.

Estas sombras incidentes en los módulos producen puntos de inflexión separados aproximadamente un tercio del voltaje de circuito abierto del panel. Cada punto de inflexión representa una corriente de cortocircuito (I_{ph}).

Vemos entonces que el módulo con mayor luminosidad presenta una corriente I_{phA} , el módulo parcialmente sombreado una I_{phB} y el módulo afectado con mayor proporción de sombra una I_{phC} .

Las curvas se obtuvieron empleando MATLAB, para enviar a través de comunicación serial, los comandos que se debían ejecutar para acceder a las funciones remotas de la carga BK PRECISION 8500 y operar en modo de Voltaje Constante. Se descartaron las curvas en las que se percibían cambios de luminosidad en el momento de generar el barrido en tensión.

En la figura 9 se muestra una de las curvas obtenidas durante la realización de este trabajo. Se observa que hay datos no concordantes y ruido. Por esta razón fue necesario escribir un algoritmo que permitiera depurar la información contenida en la curva y que posteriormente hiciera el cálculo de los puntos de inflexión mediante la primera derivada de la función obtenida. Así, el algoritmo desarrollado para procesar los datos de curvas I-V es el siguiente:

- **Depuración de datos:** Depura los datos de corriente y tensión, elimina valores consecutivos duplicados.
- **Derivada y Suavizado:** Genera la primera derivada de la función obtenida. Respecto a valores de corriente. Realiza un suavizado de la derivada obtenida para filtrar cambios producidos por ruido. Se realiza el suavizado en la derivada para evitar perder fidelidad de los datos originales.
- **Detección Cambio de Umbral:** Se estableció un umbral de manera manual, se recorre el vector de la derivada y se determinan los instantes en que la derivada es inferior y superior al umbral para detectar los puntos de inflexión. El umbral fue seleccionado a partir de una tabla en las que se anotaron las Iphs determinadas visualmente con referencia en las gráficas de las curvas I-V haciendo uso de la herramienta “Data Tip” de MATLAB. Para ello se iba variando el umbral hasta tener la aproximación más cercana a las corrientes detalladas en la tabla.
- **Verificación de Iphs Detectadas:** Verifica que los puntos de inflexión se encuentren alrededor de un tercio del voltaje de circuito abierto del panel PV. De lo contrario las Iphs detectadas pueden corresponder a ruido.
- **Resultados:** Guarda resultados de Iph como un archivo matricial (KxZ), en la ruta configurada como destino de archivo.




Figura 9. Curva característica I-V en condiciones de sombreado parcial

En la figura 11 observan los cambios de la primera derivada de una curva I-V, los cuales son producidos por los puntos de inflexión de la curva característica, de esta manera es posible detectar una probable corriente de cortocircuito cada vez que el valor de la derivada pasa de ser inferior al umbral, a ser superior.




Figura 10. Derivada con Umbral para detección de Iph.

4.2.2 Procesamiento de Imágenes. El procesamiento de las imágenes se desarrolló usando el modelo de color YCbCr, se aplicó segmentación semi-automática de módulos y un método de aprendizaje de máquina supervisado llamado Árbol de Decisión.

4.2.2.1 Recorte de Imágenes. En la figura 11 se muestra una de las imágenes del panel capturadas durante el proceso de recolección de datos. Se empleó un algoritmo para recortar la imagen con el fin de reducir información irrelevante en la imagen. Esto proporcionó velocidad de cómputo.



Figura 11. Captura recortada del panel fotovoltaico.

En la figura 12 se muestra el esquema del algoritmo desarrollado para procesar las imágenes empleadas para el entrenamiento de los modelos de estimación de I_{ph} . Una vez se recortaron las imágenes, se procedió con las siguientes etapas.




Figura 12. Algoritmo de procesamiento de imágenes para el entrenamiento.

4.2.2.2 Segmentación Semi-Automática de Módulos. En ésta etapa se determinaron 6 ecuaciones de rectas que permitían definir el contorno de cada módulo. Las ecuaciones fueron halladas a partir de coordenadas en una imagen tomada como referencia, ver figura 13. De esta manera se logró generar una plantilla para procesar la totalidad de las imágenes del Dataset.

Por tratarse de una plantilla es importante mencionar que para obtener mejores resultados se deben realizar capturas del panel manteniendo una misma perspectiva del panel. Para este trabajo se trató de mantener el punto de captura de imagen lo más estático posible con el fin de preservar la perspectiva de todas las imágenes.



Figura 13. Módulos segmentados a partir de ecuaciones de recta.

Parametrizar el panel con estas seis rectas permitió crear regiones para cada módulo y poder identificar las posiciones dentro de la imagen de los píxeles que correspondían a cada módulo. Como resultado de la segmentación se obtuvieron tres matrices o imágenes con cada módulo segmentado de la imagen original. El algoritmo es iterativo y dicho proceso se realiza para cada una de las fotografías del Dataset.

Pseudocódigo Segmentación Semi-Automática:

```

for i=1:NumFilas do
  for j=1:NumColumnas do
    if i y j estan dentro de r1,r2,r5,r6 then
      ValorDestinoMat1(i,j) = ValorOrigen(i,j)
    else if i y j estan dentro de r2,r3,r5,r6 then
      ValorDestinoMat2(i,j) = ValorOrigen(i,j)
    else if i y j estan dentro de r3,r4,r5,r6 then
      ValorDestinoMat3(i,j) = ValorOrigen(i,j)
    end if
  end for
end for
end for

```

Figura 14. Pseudocódigo para la segmentación de módulos.




Figura 15. Resultado de la segmentación de módulos.

4.2.2.3 Adecuación de Datos. En esta etapa se redimensionaron las imágenes a un 10% del tamaño original para reducir la cantidad de información a procesar. Las imágenes obtenidas por el sensor óptico se encuentran por defecto en el espacio de color RGB conformado por tres capas. Posterior al redimensionamiento, las imágenes se transformaron al espacio de color YCbCr, tomando como características para el entrenamiento los descriptores de luminancia presentes en la capa Y de dicho espacio. Finalmente se vectorizaron las imágenes para crear matrices de entrenamiento correspondientes a cada módulo. Cada fila de estas matrices contiene la información de una imagen en forma de vector. A cada fila de la matriz de entrenamiento se le asoció el valor correspondiente de Iph.

4.2.2.4 Vectorización. Proceso que consistió en transformar las matrices de cada módulo en vectores que conformaron las filas de las matrices de entrenamiento. En la figura 16 se ilustra el proceso de vectorización de cada módulo.




Figura 16. Proceso de Vectorización de matrices representativas de cada módulo.

En detalle, las matrices representativas de cada módulo o imágenes, poseían dimensiones 47x49 píxeles, al someterlas al proceso de vectorización a través de la función reshape() de MATLAB, se obtuvieron vectores de dimensiones 1x2303 que se guardaron como filas de la matriz final de entrenamiento, ésta con dimensiones 115x2304, correspondientes a 115 imágenes y 2303 valores de los módulos vectorizados más una columna de las Iph asociadas. El proceso a seguir fue el siguiente.

- Crear tres matrices de destino NxM (115x2304). Una para cada módulo.
- Redimensionar cada imagen a un 10% del tamaño original (47x49).
- Llevar las imágenes al espacio YCbCr y seleccionar la capa Y.
- Vectorizar las imágenes con la función reshape().
- Guardar vector en la matriz destino en las posiciones (Ni,(1:M-1)).
- Asociar en la posición (Ni,M) el valor correspondiente de Iph.

4.2.2.5 Asociación de Corrientes de Cortocircuito. Para realizar la asociación de I_{ph} se tuvo en cuenta que debido a la ubicación del panel y el movimiento del sol a lo largo del día, el sentido de proyección de sombra se daba de izquierda a derecha, por esta razón, la corriente más pequeña correspondía al módulo más a la izquierda y la más grande, al módulo del extremo derecho. Así fueron asignadas las corrientes a sus respectivos módulos.

Previamente las imágenes fueron organizadas de manera que las filas de las matrices de módulos, coincidieran con las filas de la matriz de I_{ph} extraídas de las curvas I-V obtenidas para cada una de las imágenes capturadas. Finalmente se crean tres archivos de valores separados por comas para realizar la fase de entrenamiento; un archivo con la información por módulo para cada una de las imágenes del Dataset. En la figura 17 se muestra en un esquema el proceso de asociación de I_{ph}




Figura 17. Ilustración método de asociación de I_{ph} .

La sombra incidente en el panel se muestra entre las líneas amarillas, los módulos están demarcados por líneas rojas e identificados por números. Así el módulo 1 se encuentra totalmente sombreado, en consecuencia, la I_{ph} asociada será la de menor valor, como se muestra en la curva I-V. De igual manera para la matriz representativa del módulo 2, se asociaría el valor de 2.042 [A] debido a que se encuentra parcialmente sombreada y al módulo 3 que se encuentra sin sombra, le será asignada la corriente de 4.627 [A]. Se muestra entonces la relación que guarda la posición de los módulos, el sentido de proyección de la sombra y la magnitud de la I_{ph} registrada en la curva I-V.

4.3 Entrenamiento

Previamente a la realización del entrenamiento, fue necesario comparar dos métodos de aprendizaje de máquina que actualmente se implementan para la solución de problemas de regresión como lo es el problema abordado en este trabajo de investigación, de igual manera se compararon dos espacios de color bastante implementados, entre estos, el espacio YCbCr y el HSV.

4.3.1 Selección de Método y Espacio de Color. El espacio de color YCbCr se tuvo en cuenta debido a que en la capa Y guarda información de la luminancia en la imagen, parámetro relacionado con la intensidad de la luz solar incidente en el panel. El espacio HSV fue considerado por poseer información del tono en la capa H; el tono del panel podría verse afectado por la sombra proyectada sobre él.

El enfoque de la etapa de selección de método y espacio de color fue realizar pruebas de entrenamiento con las imágenes del panel PV, al cual no se aplicó el proceso de segmentación de

módulos. El proceso de asociación explicado en el literal 4.2.2.5 se realizó asociando el promedio de las Iph de cada módulo a cada una de las capturas correspondientes del panel PV.

El criterio de selección escogido fue la validación cruzada, la cual se realizó con un K-fold de 10. Haciendo uso de éste criterio de ajuste, se verificaba que tan bien se adaptaba el modelo al conjunto de datos de entrenamiento y si se producía sobre ajuste en el mismo. Los resultados de la selección se presentan en la Tabla 1 de la sección de resultados.

4.3.2 Desarrollo del entrenamiento. Una vez las curvas y las imágenes fueron procesadas, las matrices de entrenamiento armadas y guardadas como archivos separados por coma, se procedió con la fase de aprendizaje. Como se mencionó anteriormente, el método que se seleccionó fue el árbol de decisión al trabajar con los descriptores de luminancia del espacio YCbCr. Las matrices de entrenamiento cumplen la función de relacionar un conjunto de datos X o entrada con un conjunto de datos Y o salida, como se muestra en la figura 18.




Figura 18. Desglose de matriz de entrenamiento.

De las 115 imágenes representadas en las filas de la matriz de entrenamiento, el 75% fue empleado como conjunto de entrenamiento y el 25% restante como conjunto de prueba o

validación de resultados. Teniendo clara la distribución de los datos, se detalla de manera precisa el procedimiento en Python. Ver figura 19.



```
Est=DecisionTreeRegressor() : Objeto
Est.fit(Xdata,Ydata) : 75% X,Y data
Est.predict(Xdata) : Ydata | 25% Xdata
RMSE(Ydata,Ydata)

Si RMSE <= 0.2 [A] Se guarda Modelo
```

Figura 19. Procedimiento en Python.

Se creó un objeto de tipo “regresor de árbol de decisión” usando el módulo Sklearn de python. A partir de este objeto es posible usar el método “.fit” el cual recibe el conjunto de datos X e Y de entrenamiento y se encarga de ajustar el modelo. Una vez se ha obtenido el modelo, se puede hacer uso de él a través del método “.predict” que se encarga de procesar el conjunto de datos de prueba y estimar las salidas Y’. Finalmente se compararon los valores estimados contra los valores conocidos de corrientes. Para ello se usó la raíz del error cuadrático medio como parámetro de error. Se estableció un error máximo aceptable de 0.2 [A] teniendo en cuenta el rango de operación del panel PV que va desde los 500 [mA] hasta los 8.86 [A]. El modelo que cumplía con dicha condición, era guardado.

La escritura del código de entrenamiento se realizó en Python 3.5 haciendo uso de los módulos pandas, numpy y matplotlib para el manejo de datos. Ver anexos para observar el código implementado. Los resultados del entrenamiento se muestran en la sección de resultados. El tiempo de entrenamiento fue de aproximadamente 10 minutos para los tres módulos.

4.4 Uso del Algoritmo

Tras haber realizado el entrenamiento de los modelos en python, fue posible implementarlos en el desarrollo del algoritmo. Los modelos fueron creados en Python 3.5 como archivos de extensión “.pkl”, se usaron funciones de matlab que llaman a ejecución el código escrito en python (“Iph_prediction.py”), el cual retorna mediante impresión en la consola de matlab, los resultados estimados de las Iph correspondientes. Estas líneas adicionales fueron introducidas en una versión modificada del algoritmo presentado en la figura 12. El esquema de funcionamiento del algoritmo es el que se muestra en la figura 20.




Figura 20. Esquema de funcionamiento del Algoritmo Final.

El algoritmo fue escrito para permitirle al usuario seleccionar una de las opciones que aparecen en el menú cuando se inicia la ejecución del código.

La función recortar permite al usuario hacer un recorte de las imágenes que se encuentran en la carpeta “Img_Path”, esta ruta puede ser configurada en los parámetros especificados en las líneas de código del algoritmo en matlab. Allí el usuario puede definir el punto inicial a partir del que se realizará el recorte, el ancho y el alto en píxeles que tendrá la imagen a ser recortada.

Al finalizar el recorte de una o varias imágenes, las guardará en el directorio configurado como “Crop_Path”. Terminado este proceso, la ejecución habrá finalizado.

Por otra parte, la función estimar Iphs, permite al usuario realizar la estimación de las Iphs de una o varias imágenes guardadas en “Crop_Path”, es importante que las imágenes que se sitúen en dicha carpeta estén recortadas para obtener mejores resultados. Una vez haya leído las imágenes en la carpeta de trabajo, procederá a realizar los mismos pasos explicados en el algoritmo de la figura 12, con excepción de la asociación de Iphs. Por lo anterior, las matrices resultantes tendrán una columna menos. Las matrices ahora constituyen únicamente datos de entrada X para los cuales cada uno de los modelos estimará una salida Y.

Una vez se hayan creado las matrices de datos X, se realiza un llamado mediante comandos del sistema al código de python que permite cargar los modelos así como también los datos contenidos en las matrices de entradas X. El código utiliza los métodos de estimación de árbol de decisión contenidos en el módulo sklearn de python para tomar como entrada las matrices X y producir las salidas Y, las cuales serán impresas y mostradas en la consola de matlab.

El algoritmo es capaz de estimar y mostrar de manera ordenada los resultados obtenidos al procesar una o varias imágenes. El algoritmo está escrito para ser fácilmente modificado y poder procesar imágenes que tengan perspectivas diferentes. Para ello también se deberá modificar las

ecuaciones de rectas que definen las regiones de módulo, de igual manera, se deberá realizar un proceso de entrenamiento nuevo, generando modelos acordes a la nueva situación.

5. Resultados

5.1 Resultados selección de método de aprendizaje y espacio de color

Tal como se explicó en el literal 4.3.1, se realizó la comparación entre los métodos de aprendizaje SVM y DT igualmente entre los espacios de color YCbCr y HSV. Los resultados del experimento bajo criterio de la validación cruzada son los siguientes.

Tabla 1. *Resultados para imágenes de un panel PV con Iph promedio asociada.*

Espacio/Método	SVM	Decision Tree
HSV - Hue	1.458 (+/- 0.93932)	1.210 (+/- 1.13612)
YCbCr - Y	1.481 (+/- 1.27759)	0.338 (+/- 0.06181)

Los resultados son expresados en términos de la raíz del error cuadrático medio (RMSE). Cómo se puede observar, el menor error se obtiene al emplear el modelo de color YCbCr y el método de entrenamiento Árbol de Decisión. Razón por la que fueron escogidos para la elaboración del algoritmo.

5.2 Resultados del entrenamiento.

Tras haber realizado múltiples entrenamientos con el fin de obtener modelos que cumplieran con el criterio del máximo error establecido en 0.2 [A], se obtuvieron los siguientes resultados.

```
Validando...  
Entrenamiento Terminado. Resultados:  
Error M1:0.173  
Error M2:0.179  
Error M3:0.194  
Resutados de acuerdo a un error aceptable de: 0.2
```

Figura 21. Resultados del entrenamiento de los modelos.

El error está dado en Amperios. Así para el modelo de estimación de I_{ph} del módulo 1 se tiene un error de 0.173 [A], para el modelo del módulo 2 un error de 0.179 [A] y para el del módulo 3 un error de 0.194 [A].

5.3 Resultados del Algoritmo

Se procesaron las 29 imágenes del conjunto de prueba de forma aleatoria. Se realizó un diagrama de dispersión o scatter plot para analizar la relación existente entre las corrientes conocidas y las corrientes estimadas por el algoritmo. Ver figura 22.

Los resultados se obtuvieron en un tiempo de 57.56 segundos, esto es, 1.98 segundos por imagen o 0.66 segundos por módulo. El error RMSE máximo fue de ± 0.194 [A] y el mínimo de ± 0.173 [A]. El margen de error RMSE tolerado fue de ± 0.2 [A], considerado aceptable teniendo como referencia el rango de operación e corriente del panel PV, el cual va desde los 0.5 [A] en condiciones de baja irradiancia, hasta su corriente de cortocircuito de 8 [A] ante máxima irradiancia.

Con base en estos resultados se logró demostrar de manera empírica una relación estrecha entre la información de luminancia en las imágenes y las corrientes de cortocircuito de cada uno de los módulos.




Figura 22. Resultados en la estimación de corrientes por módulo.

Se puede observar una tendencia lineal en la relación que guardan las corrientes conocidas y las corrientes estimadas, esto demuestra que los modelos de predicción se entrenaron de manera satisfactoria y que son efectivos a la hora de predecir las corrientes de cortocircuito a partir de las imágenes procesadas.

6. Conclusión

Debido a los esfuerzos por popularizar las energías renovables y al gran avance que ha tenido la tecnología en el campo de la energía solar, este artículo centra su atención en un método que aporta a la optimización energética de los paneles PV. Se presenta entonces, el desarrollo de un algoritmo capaz de estimar las corrientes de cortocircuito (I_{ph}) de un panel fotovoltaico de tres módulos a partir del procesamiento de imágenes.

Pocos artículos se centran en soluciones basadas en sistemas de reconocimiento a través de visión por computador, en cambio, se basan principalmente en técnicas de reconfiguración de arreglos fotovoltaicos o monitoreo de las características de Potencia-Tensión de los paneles PV, éstas pueden resultar en implementaciones complejas e intrusivas para la operación del panel PV.

De acuerdo a la metodología propuesta, se capturaron imágenes de un panel PV a medida que iba variando la proyección de sombra incidente sobre él, a su vez, se generaron barridos en tensión para obtener las curvas características I-V con las que se extrajeron los valores de I_{ph} teóricos para cada imagen. Las imágenes fueron procesadas en matlab y llevadas al espacio YCbCr. Posteriormente se determinó la capa de luminancia (Y) como característica principal para el entrenamiento y se segmentaron los módulos del panel de manera semi-automática usando ecuaciones de recta que definieron regiones pertenecientes a cada módulo del panel PV, esto permitió generar una plantilla para procesar el conjunto completo de imágenes. Las imágenes de módulos segmentados fueron redimensionadas y vectorizadas para crear las matrices de datos necesarias para entrenar los modelos. El entrenamiento se realizó con el método de aprendizaje de máquina llamado árbol de decisión.

Los resultados obtenidos del entrenamiento muestran variaciones de la raíz del error cuadrático medio de ± 0.182 [A] en promedio en cuanto a la estimación de I_{phs} . Las I_{phs} de los módulos de las imágenes de prueba fueron estimadas en un periodo corto de tiempo no mayor a 2 minutos y con un margen de error aceptable (inferior a ± 0.2 [A]) si se consideran las corrientes de operación dentro de un rango de 0.5 [A] hasta 8.86 [A]. Los resultados también muestran de manera empírica que la información de los descriptores de luminancia en la imagen guarda gran relación con la magnitud de las I_{phs} , además de mostrar que el método de árbol de decisión es eficiente debido a que con una pequeña cantidad de imágenes de muestra fue posible obtener una buena precisión en la estimación de I_{phs} , esto se verificó al comparar los resultados estimados con los valores teóricos identificados en las curvas I-V.

El método presentado en esta investigación puede ser aplicado en la estimación de las corrientes de cortocircuito de un panel PV y de esta manera se podrían alimentar modelos que permitan ubicar con mayor eficacia el MPP de un panel PV, mejorando la eficiencia en la captación de energía solar. La ventaja del método propuesto se encuentra en su carácter no intrusivo, fácil implementación, buena precisión y bajos costos. La estimación bajo condiciones de sombra con diferente geometría, así como la segmentación automática de módulos desde cualquier perspectiva de captura de imagen, deben ser mejoradas en futuras investigación para ofrecer un algoritmo más robusto.

Referencias Bibliográficas

- Accarino, J., Petrone, G., Ramos-Paja, C. A., & Spagnuolo, G. (2013). Symbolic algebra for the calculation of the series and parallel resistances in PV module model. *4th International Conference on Clean Electrical Power: Renewable Energy Resources Impact, ICCEP 2013*, 62–66. <https://doi.org/10.1109/ICCEP.2013.6586967>
- Díaz-Dorado, E., Suárez-García, A., Carrillo, C., & Cidrás, J. (2010). Influence of the shadows in photovoltaic systems with different configurations of bypass diodes. *SPEEDAM 2010 - International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, 134–139. <https://doi.org/10.1109/SPEEDAM.2010.5542226>
- Kern, E. C., & Russell, M. C. (2003). Spatial and temporal irradiance variations over large array fields, 1043–1050 vol.2. <https://doi.org/10.1109/pvsc.1988.105864>
- Kuszamaul, S., Ellis, A., Stein, J., & Johnson, L. (2010). Lanai High-Density Irradiance Sensor Network for characterizing SOLAR resource variability of MW-scale PV system. *Conference Record of the IEEE Photovoltaic Specialists Conference*, 283–288. <https://doi.org/10.1109/PVSC.2010.5615868>
- Patel, H., & Agarwal, V. (2008). Maximum power point tracking scheme for PV systems operating under partially shaded conditions. *IEEE Transactions on Industrial Electronics*, 55(4), 1689–1698. <https://doi.org/10.1109/TIE.2008.917118>
- Patnaik, B., Aswani, U., Sarkar, G., & Duttagupta, S. P. (2014). Image aided dynamic reconfiguration of SPV array under non uniform illumination. *2014 IEEE 40th Photovoltaic Specialist Conference, PVSC 2014*, 797–802. <https://doi.org/10.1109/PVSC.2014.6925037>
- Rabinovici, R., & Dagan, T. (2012). Assessment of solar irradiance in Large-Scale Photovoltaic

fields by means of video processing. *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel, IEEEI 2012*, 1–5.

<https://doi.org/10.1109/IEEEI.2012.6377032>

Rabinovici, R., & Frechter, Y. B. (2010). Solar cell single measurement maximum power point tracking. *2010 IEEE 26th Convention of Electrical and Electronics Engineers in Israel, IEEEI 2010*, 26–30. <https://doi.org/10.1109/IEEEI.2010.5662186>



Xu, Q., Song, J., Bian, H., Yukita, K., & Ichiyanagi, K. (2010). Analysis of photovoltaic array performance under shaded conditions. *Asia-Pacific Power and Energy Engineering Conference, APPEEC*, (50907010), 10–13. <https://doi.org/10.1109/APPEEC.2010.5449472>

Apéndices


A. Hoja de datos panel PV utilizado

TSM-PC05 / TSM-PA05 THE UNIVERSAL SOLUTION

DIMENSIONS OF PV MODULE TSM-PC/PA05




I-V CURVES OF PV MODULE TSM-245 PC/PA05



Average efficiency reduction of 4.5% at 200W/m² according to EN 60904-1.

CERTIFICATION



ELECTRICAL DATA @ STC	TSM-235 PC/PA05	TSM-240 PC/PA05	TSM-245 PC/PA05	TSM-250 PC/PA05
Peak Power Watts-P _{MAX} (Wp)	235	240	245	250
Power Output Tolerance-P _{MAX} (%)	0/+3	0/+3	0/+3	0/+3
Maximum Power Voltage-V _{MPP} (V)	29.3	29.7	30.2	30.3
Maximum Power Current-I _{MPP} (A)	8.03	8.10	8.13	8.27
Open Circuit Voltage-V _{OC} (V)	37.2	37.3	37.5	37.6
Short Circuit Current-I _{SC} (A)	8.55	8.62	8.68	8.85
Module Efficiency η _m (%)	14.4	14.7	15.0	15.3

Values at Standard Test Conditions STC (Air Mass AM1.5, Irradiance 1000W/m², Cell Temperature 25°C). Power measurement tolerance: ±3%

ELECTRICAL DATA @ NOCT	TSM-235 PC/PA05	TSM-240 PC/PA05	TSM-245 PC/PA05	TSM-250 PC/PA05
Maximum Power-P _{MAX} (Wp)	171	174	178	181
Maximum Power Voltage-V _{MPP} (V)	26.4	26.6	26.8	27.0
Maximum Power Current-I _{MPP} (A)	6.48	6.55	6.64	6.70
Open Circuit Voltage [V]-V _{OC} (V)	34.0	34.1	34.2	34.3
Short Circuit Current [A]-I _{SC} (A)	6.97	7.04	7.10	7.25

NOCT: Irradiance at 800W/m², Ambient Temperature 20°C, Wind Speed 1m/s. Power measurement tolerance: ±3%

MECHANICAL DATA

Solar cells	Multicrystalline 156 × 156mm (6 inches)
Cell orientation	60 cells (6 × 10)
Module dimensions	1650 × 992 × 40mm (64.95 × 39.05 × 1.57 inches)
Weight	19.5kg (43.0 lb)
Glass	High transparency solar glass 3.2mm (0.13 inches)
Frame	Anodized aluminium alloy
J-Box	IP 65 rated
Cables	Photovoltaic Technology cable 4.0mm² (0.006 inches²), 1000mm (39.4 inches)
Connector	MC4  

TEMPERATURE RATINGS

Nominal Operating Cell Temperature (NOCT)	45°C (±2°C)
Temperature Coefficient of P _{MAX}	-0.43%/°C
Temperature Coefficient of V _{OC}	-0.32%/°C
Temperature Coefficient of I _{SC}	0.047%/°C

MAXIMUM RATINGS

Operational Temperature	-40~+85°C
Maximum System Voltage	1000V DC(IEC)/600V DC(UL)
Max Series Fuse Rating	15A

WARRANTY

10 year workmanship warranty
25 year linear performance warranty
(Please refer to product warranty for details)

PACKAGING CONFIGURATION

Modules per box: 24 pcs
Modules per 40' container: 672 pcs

B. Error relativo entre corrientes conocidas y corrientes estimadas.

Errores Relativos		
Iph1	Iph2	Iph3
0.0243	0.0243	0.0182
0.2286	0.0000	0.1598
0.0000	0.2674	0.0000
0.0000	0.2760	0.0000
0.0000	0.1235	0.1619
0.3181	0.0000	0.0025
0.0000	0.0000	0.4257
0.0000	0.0000	0.2184
0.0000	0.0000	0.1439
0.2422	0.0000	0.0000
0.0000	0.1681	0.0000
0.0375	0.0000	0.0011
0.0364	0.0364	0.0000
0.0175	0.0350	0.0000
0.0000	0.1930	0.1751
0.0000	0.0000	0.0456
0.0000	0.0337	0.0000
0.0114	0.0000	0.0326
0.0137	0.0271	0.0144
0.1200	0.0636	0.0807
0.0155	0.0000	0.1273
0.2437	0.0000	0.0822
0.0000	0.1316	0.0000
0.0000	0.1658	0.0000
0.0000	0.0000	0.0550
0.0098	0.0000	0.0575
0.0000	0.0212	0.0333
0.0000	0.2080	0.0000
0.2429	0.0522	0.0000