

**DISEÑO DE UN SISTEMA BASADO EN REGLAS PARA
CONTROLAR LA IRRIGACIÓN DE UN PANEL FOTOVOLTAICO
ORIENTADO AL BENEFICIO ENERGÉTICO**

**TANIA JOHANNA ÁVILA SUÁREZ
DANNY JAMES PÉREZ RODRÍGUEZ**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍAS
ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
BUCARAMANGA**

2020

**DISEÑO DE UN SISTEMA BASADO EN REGLAS PARA
CONTROLAR LA IRRIGACIÓN DE UN PANEL FOTOVOLTAICO
ORIENTADO AL BENEFICIO ENERGÉTICO**

**TANIA JOHANNA ÁVILA SUÁREZ
DANNY JAMES PÉREZ RODRÍGUEZ**

**Trabajo de Grado para optar al título de
Ingeniero Electricista**

**Director
Javier Solano
Doctor en Ingeniería Eléctrica**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍAS
ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
BUCARAMANGA**

2020

DEDICATORIA

A Dios y a la virgen María como principal fuente de mi vida, por amarme, protegerme y orientarme con sabiduría y dedicación para culminar esta maravillosa etapa.

A mis padres Yaneth Suarez y Nelson Ávila por ser mi constante motivación para salir adelante, por sus palabras, por sus actos de amor incondicional, por dejarme esta maravillosa herencia de la educación, sin ellos nada de este triunfo hubiera sido posible.

A mis hermanas, Karen Ávila y Freya Clarice por ser mi ejemplo y motivarme a seguir luchando, por ser mi refugio y mi luz en tiempos oscuros, porque son mi talismán en cada instante de mi vida.

A mi maravillosa Sobrina Eileen Gabriela, que llegó en el mejor momento de mi vida, a ser un motivo más para culminar la mejor etapa.

A mi novio, Diego Rojas por apoyarme, guiarme y ser mi mejor mentor en la mitad de mi carrera, porque no me dejó desfallecer, por sus sabias palabras y por el amor tan bonito que me expresa día a día.

A mi compañero y amigo de tesis Danny James por que juntos con esfuerzo, peleas, risas, y preocupaciones logramos culminar este proyecto de la mejor manera, y demás amigos que desde el inicio estuvieron conmigo aportándome las virtudes tan excepcionales que los caracteriza.

Tania

A mi mamá Damaris, que a pesar de todo, soy lo que soy gracias a lo que ella me ha enseñado; por apoyarme en todas mis decisiones, por darme todo lo que he necesitado y por ser el pilar de mi vida.

A mis hermanas Danna, Marihec y Nathalia por enseñarme a ser paciente y motivarme a salir adelante a que construyamos juntos un mejor futuro para toda nuestra familia y amigos.

A mis abuelas Alicia y Ana, por sus consejos y la sabiduría infinita con la que han permeado mi vida.

A mis tías Isabel, Milena y Sara por siempre darme el amparo que he necesitado en aquellos momentos duros de la vida, por quererme incondicionalmente.

A mi mejor amiga Angie Zulay, por su sempiterna amistad, por amarme sin condiciones y dejarme amarla con todas mis fuerzas.

A mi mejor amiga Anny, que sigue estando incondicional en mi vida, que me quiere como un hermano, que me da ánimos a hacer lo que ni yo creo alcanzable.

A mis amigas Tania y Paola, que gracias a ellas pudimos salir adelante y culminar esta parte del camino que apenas empieza.

“¿Hacia dónde os llevamos? Os llevaremos a dónde nos digáis. Vosotros lo que queréis es que encontremos una ley universal. Al final os llevaremos hacia la nada, donde las líneas paralelas se encuentran, donde las cosas no son falsas ni ciertas, juntos de la mano hacia la nada.”

—Hidrogenesse, *Historia del mundo contada por las máquinas*

James

AGRADECIMIENTOS

Al Dr. Javier Solano, por su apoyo y confianza durante este proceso.

A todos nuestros compañeros, compañeras y profesores que conocimos en el camino, gracias por ayudarnos a convertirnos en lo que terminamos siendo.

TABLA DE CONTENIDO

	pág.
INTRODUCCIÓN	15
1. OBJETIVOS	17
2. PLANTEAMIENTO DEL PROBLEMA	18
2.1. IRRIGACIÓN CONTINUA	18
2.2. IRRIGACIÓN EN REGÍMENES	19
2.3. IRRIGACIÓN CONTROLADA POR PROGRAMACIÓN DINÁMICA	20
2.4. POTENCIA GENERADA	21
2.5. MODELO TÉRMICO DEL PANEL FOTOVOLTAICO	22
2.5.1. Puntos de temperatura	22
2.5.2. Transferencia de calor	23
2.5.3. Temperatura del panel fotovoltaico sin incluir el sistema de irrigación	25
2.5.4. Comportamiento térmico del agua de riego	26
2.5.5. Temperatura del panel fotovoltaico considerando el sistema de irrigación	26
3. SISTEMA BASADO EN REGLAS	27
3.1. APRENDIZAJE AUTOMÁTICO BASADO EN REGLAS	28
3.2. ALGORITMO LCS	29
4. IMPLEMENTACIÓN DEL CASO DE ESTUDIO EN EL SBR	30
4.1. DATOS EN CRUDO	30
4.2. VERIFICACIÓN DE LA INTEGRIDAD DE LOS DATOS IMPORTADOS	32
4.3. CÁLCULO DE LOS PERFILES ÓPTIMOS	32

4.4. GENERACIÓN DE LOS CONJUNTOS DE DATOS DE ENTRENAMIENTO Y DE PRUEBA	32
4.5. IMPLEMENTACIÓN DEL LCS	33
4.5.1. Conjunto de datos	34
4.5.2. Conjunto de población de reglas [P]	34
4.5.3. Conjunto de coincidencias [M]	34
4.5.4. Covering	35
4.5.5. Matriz de predicciones	35
4.5.6. Conjunto correcto e incorrecto [C] e [I]	36
4.5.7. Actualización de los parámetros de las reglas	36
4.5.8. Subsunción	36
4.5.9. Algoritmo genético	36
4.5.10. Eliminación	36
4.5.11. Compactación de reglas	36
4.6. GENERACIÓN DEL SISTEMA BASADO EN REGLAS	37
4.6.1. Cantidad de instancias	38
4.6.2. Conjunto de datos de entrenamiento balanceado	38
4.6.3. Tamaño de la población	38
4.6.4. Cantidad de iteraciones	38
4.6.5. Algoritmo de conocimiento experto	38
4.6.6. Algoritmo de compactación de reglas	39
4.6.7. Parámetros del SBR candidato	39
4.7. SIMULACIÓN DEL SISTEMA	39
5. CASO DE ESTUDIO	42
5.1. Análisis y gráficas del día 93	43
5.2. Análisis y gráficas del día 104	46
5.3. Análisis y gráficas del día 219	49

5.4. Análisis y gráficas del día 230	52
5.5. Análisis y gráficas del día 253	55
5.6. Análisis y gráficas del día 282	58
5.7. Análisis y gráficas del día 286	61
BIBLIOGRAFÍA	64
ANEXOS	69

LISTA DE FIGURAS

	pág.
Figura 1. Modelo térmico RC del panel FV	22
Figura 2. Diagrama del flujo de trabajo para obtener el Sistema Basado en Reglas	31
Figura 3. Estrategia de covering del algoritmo	35
Figura 4. Recorrido de una instancia de entrenamiento a través de la implementación de un algoritmo LCS de estilo Michigan	37
Figura 5. Esquemático de la estructura de un sector de los scripts y vector que fue reemplazado para calcular los resultados	40
Figura 6. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 93.	43
Figura 7. Potencia beneficio SBR vs PD vs sin irrigación, día 93.	44
Figura 8. Energía beneficio SBR vs PD vs sin irrigación, día 93.	45
Figura 9. Potencia de irrigación SBR vs PD, día 93.	45
Figura 10. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 104.	46
Figura 11. Potencia beneficio SBR vs PD vs sin irrigación, día 104.	47
Figura 12. Energía beneficio SBR vs PD vs sin irrigación, día 104.	48
Figura 13. Potencia de irrigación SBR vs PD, día 104.	48
Figura 14. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 219.	49
Figura 15. Potencia beneficio SBR vs PD vs sin irrigación, día 219.	50
Figura 16. Energía beneficio SBR vs PD vs sin irrigación, día 219.	51

Figura 17.	Potencia de irrigación SBR vs PD, día 219.	51
Figura 18.	Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 230.	52
Figura 19.	Potencia beneficio SBR vs PD vs sin irrigación, día 230.	53
Figura 20.	Energía beneficio SBR vs PD vs sin irrigación, día 230.	54
Figura 21.	Potencia de irrigación SBR vs PD, día 230.	54
Figura 22.	Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 253.	55
Figura 23.	Potencia beneficio SBR vs PD vs sin irrigación, día 253.	56
Figura 24.	Energía beneficio SBR vs PD vs sin irrigación, día 253.	57
Figura 25.	Potencia de irrigación SBR vs PD, día 253.	57
Figura 26.	Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 282.	58
Figura 27.	Potencia beneficio SBR vs PD vs sin irrigación, día 282.	59
Figura 28.	Energía beneficio SBR vs PD vs sin irrigación, día 282.	60
Figura 29.	Potencia de irrigación SBR vs PD, día 282.	60
Figura 30.	Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 286.	61
Figura 31.	Potencia beneficio SBR vs PD vs sin irrigación, día 286.	62
Figura 32.	Energía beneficio SBR vs PD vs sin irrigación, día 286.	63
Figura 33.	Potencia de irrigación SBR vs PD, día 286.	63

LISTA DE TABLAS

	pág.
Tabla 1. Detalle de la estructura del conjunto de datos de entrenamiento y de prueba	33

LISTA DE ANEXOS

	pág.
Anexo A. Determinación de los parámetros del mecanismo de aprendizaje del LCS	69
Anexo B. Software utilizado para generar el SBR	73

RESUMEN

TÍTULO: DISEÑO DE UN SISTEMA BASADO EN REGLAS PARA CONTROLAR LA IRRIGACIÓN DE UN PANEL FOTOVOLTAICO ORIENTADO AL BENEFICIO ENERGETICO *

AUTORES: TANIA JOHANNA ÁVILA SUÁREZ, DANNY JAMES PÉREZ RODRÍGUEZ **

PALABRAS CLAVE: Eficiencia, Sistema Basado en Reglas, Sistema Clasificador de Aprendizaje, Paneles Fotovoltaicos, Energía, Radiación, Temperatura, Irrigación.

DESCRIPCIÓN:

El panel fotovoltaico (FV) es el principal recurso para la transformación de la energía solar, su eficiencia eléctrica y potencia de salida dependen de la temperatura de operación. El presente trabajo de grado tiene como objetivo diseñar un Sistema Basado en Reglas (SBR) para mejorar el beneficio energético de un panel fotovoltaico (FV) al controlar su módulo de irrigación de forma autónoma. Los resultados demuestran que se puede obtener un beneficio de hasta un 2.92 % de energía neta comparado con un sistema FV sin irrigación. Una implementación de este control de irrigación inteligente podría suponer también beneficios económicos en sistemas de producción de energía eléctrica fotovoltaica, requiriendo únicamente inversiones mínimas de infraestructura por parte de las entidades interesadas.

Nuestro SBR toma ventaja de capacidades desarrolladas por un Algoritmo Clasificador de Aprendizaje (LCS) para especializarse en descubrimiento de conocimiento, minado de datos y tareas de predicción. Más de un año de datos medidos (irradiancia, temperatura ambiente, velocidad del viento) por los sensores instalados en el sistema fotovoltaico del techo verde del edificio de la Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones en la Universidad Industrial de Santander han sido utilizados para el entrenamiento y la validación de este modelo.

* Trabajo de grado

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: Javier Enrique Solano Martínez, Doctor en Ingeniería Eléctrica

ABSTRACT

TITLE: DESIGN OF A RULE-BASED SYSTEM TO CONTROL THE IRRIGATION OF A PHOTOVOLTAIC PANEL AIMED AT ENERGY BENEFIT *

AUTHORS: TANIA JOHANNA ÁVILA SUÁREZ, DANNY JAMES PÉREZ RODRÍGUEZ **

KEYWORDS: Efficiency, Rule-Based System, Learning Classifier System, Photovoltaic Panels, Energy, Radiation, Temperature, Irrigation.

DESCRIPTION:

The photovoltaic (PV) panel is the main resource for the transformation of solar energy. Its electrical efficiency and output power depend on the operating temperature. This degree work aims to design a Rule-Based System (RBS) to improve the energy benefit of a photovoltaic (PV) panel by controlling its irrigation module autonomously. The results show that a net energy benefit of up to 2.92% can be obtained compared to a PV system without irrigation. An implementation of this intelligent irrigation control could also bring economic benefits to PV electricity production systems, requiring only minimal infrastructure investment by the entities concerned.

Our SBR takes advantage of capabilities developed by a Learning Classifier Algorithm (LCS) to specialize in knowledge discovery, data mining and forecasting tasks. More than one year of measured data (irradiance, ambient temperature, wind speed) from the sensors installed in the photovoltaic system of the green roof of the building of the School of Electrical, Electronic and Telecommunication Engineering at the Industrial University of Santander have been used for the training and validation of this model.

* Bachelor Thesis

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: Javier Enrique Solano Martínez, Doctor en Ingeniería Eléctrica

INTRODUCCIÓN

La eficiencia eléctrica y la potencia de salida de un panel fotovoltaico (FV) dependen de su temperatura de operación¹². A mayor temperatura en la superficie de un panel FV, menor es la tensión de máxima potencia y la tensión de circuito abierto³, ocasionando una reducción de la potencia máxima generada por el panel FV⁴.

Para mejorar el rendimiento energético y térmico se utilizan técnicas de climatización, como implementar techos verdes debajo del panel FV⁵, ventilación natural⁶, irrigación en la superficie superior del panel FV⁷, entre otras. La irrigación en la superficie de un panel FV, a pesar de ser más costosa, es más efectiva que la ventilación natural⁷. Esta

-
- ¹ Swapnil Dubey, Jatin Narotam Sarvaiya y Bharath Seshadri. «Temperature Dependent Photovoltaic (PV) Efficiency and Its Effect on PV Production in the World – A Review». en. En: *Energy Procedia* 33 (2013), págs. 311-321. DOI: 10.1016/j.egypro.2013.05.072.
 - ² Hashim A Hussien, Ali H Numan y Abdulmunem R Abdulmunem. «Improving of the photovoltaic / thermal system performance using water cooling technique». En: *IOP Conference Series: Materials Science and Engineering* 78 (abr. de 2015), pág. 012020. DOI: 10.1088/1757-899X/78/1/012020.
 - ³ Arman Molki. «Temperature effect on photovoltaic cells». En: *Physics Education* 46.5 (sep. de 2011), págs. 523-525. DOI: 10.1088/0031-9120/46/5/F08.
 - ⁴ JM Olchowik y col. «Influence of temperature on the efficiency of monocrystalline silicon solar cells in the South-eastern Poland conditions». En: *Materials Science-Poland* 24.4 (2006), págs. 1127-1132.
 - ⁵ German Alfonso Osma Pinto. «Uso racional de la energía a partir del diseño de aplicaciones sostenibles en el edificio eléctrica II de la Universidad Industrial De Santander». En: 2013.
 - ⁶ Leon Gaillard y col. «Experimental evaluation of a naturally ventilated PV double-skin building envelope in real operating conditions». en. En: *Solar Energy* 103 (mayo de 2014), págs. 223-241. DOI: 10.1016/j.solener.2014.02.018.
 - ⁷ Universidad Industrial de Santander y col. «Mejoramiento del desempeño de paneles fotovoltaicos a partir de la irrigación forzada de la superficie superior». En: *Revista UIS Ingenierías* 16.2 (sep. de 2017), págs. 161-172. DOI: 10.18273/revuin.v16n2-2017015.

técnica de climatización con irrigación permite disipar el calor y mejorar la eficiencia al aumentar la potencia eléctrica de salida².

En este trabajo de grado presentamos el diseño de un Sistema Basado en Reglas (SBR) que controla de forma inteligente y autónoma el módulo de irrigación de un panel fotovoltaico. Observamos un beneficio energético de hasta 2.92% comparado con un sistema FV que no cuenta con irrigación.

Utilizamos el modelamiento de un panel FV con parámetros físicos similares al sistema instalado en el techo verde del edificio de la Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones en la Universidad Industrial de Santander.

1. OBJETIVOS

Objetivo general

- Diseñar un sistema basado en reglas para controlar la irrigación de un panel fotovoltaico.

Objetivos específicos

- Utilizar la herramienta desarrollada en el proyecto de grado previo⁸ para implementar al menos 30 perfiles medidos diarios y así obtener los perfiles de irrigación ideales.
- Identificar por observación patrones recurrentes que se presentan en los perfiles ideales.
- Proponer un sistema de control basado en reglas inspiradas en los patrones recurrentes y sus condiciones de operación.
- Establecer un algoritmo con la herramienta computacional MATLAB y en el lenguaje Python, para el sistema basado en reglas identificado.
- Comparar los resultados obtenidos del sistema basado en reglas y el sistema de programación dinámica para cuantificar la aproximación a la respuesta ideal y determinar su beneficio.

⁸ Miguel Ángel Caro Padilla y Diego Fernando Rojas Luna. *Optimización del tiempo de irrigación de un panel fotovoltaico orientado a la maximización del beneficio energético*. Trabajo de Grado para optar al título de Ingeniero Electricista de la Universidad Industrial de Santander. 2019.

2. PLANTEAMIENTO DEL PROBLEMA

Según diversos estudios, los métodos de refrigeración basados en agua proveen incrementos significativos en la potencia de salida de un panel FV. La irrigación permite reducir el calor almacenado en el panel FV debido a la transferencia de calor por convección entre el agua circulante y la superficie frontal del panel. Esto reduce la temperatura de operación del panel FV provocando un incremento en la potencia de salida². Sin embargo, activar el sistema de irrigación requiere energía, que generalmente es tomada directamente de la generada por el panel FV. El problema recae entonces en cuándo activar el sistema de irrigación. Se han estudiado diversas técnicas para encontrar el momento adecuado para activar la irrigación, descritas a continuación.

2.1. IRRIGACIÓN CONTINUA

Esta técnica consiste en hacer pasar una película de agua sobre la superficie superior del panel FV durante varias horas sin interrupciones, generalmente en el intervalo cuando hay mayor irradiación solar (9 AM a 3 PM), aunque también se han hecho experimentos con una ventana de tiempo más amplia⁹.

En pruebas realizadas por Nižetić¹⁰, la temperatura de operación del panel FV se reduce considerablemente cuando la irradiancia es alta, derivando en una potencia de salida

⁹ Saad Odeh y Masud Behnia. «Improving Photovoltaic Module Efficiency Using Water Cooling». en. En: *Heat Transfer Engineering* 30.6 (mayo de 2009), págs. 499-505. DOI: 10.1080/01457630802529214.

¹⁰ S. Nižetić, E. Giama y A.M. Papadopoulos. «Comprehensive analysis and general economic-environmental evaluation of cooling techniques for photovoltaic panels, Part II: Active cooling techniques». en. En: *Energy Conversion and Management* 155 (ene. de 2018), págs. 301-323. DOI: 10.1016/j.enconman.2017.10.071.

hasta un 20 % mayor^{10 11 12}, pero si la irradiancia disminuye por debajo de cierto umbral, el beneficio de la potencia de salida es afectado drásticamente. Otros estudios se han hecho en diversas partes del mundo^{9 12 13 14 15}. La potencia beneficio obtenida con irrigación continua puede variar de 0.7 %¹⁶ a 27.6 %¹⁷.

2.2. IRRIGACIÓN EN REGÍMENES

Debido al amplio rango de beneficio en la potencia de salida en los estudios hechos con irrigación continua, se hace complicado conocer fiablemente el impacto de utilizar esa técnica. Hasta hace poco, existía poca o nula información sobre la implementación de

-
- ¹¹ S. Nižetić y col. «Water spray cooling technique applied on a photovoltaic panel: The performance response». en. En: *Energy Conversion and Management* 108 (ene. de 2016), págs. 287-296. DOI: 10.1016/j.enconman.2015.10.079.
- ¹² M. Habibollahi, M. Ameri y S. H. Mansouri. «Efficiency Improvement of Photovoltaic Water Pumping Systems by Means of Water Flow Beneath Photovoltaic Cells Surface». en. En: *Journal of Solar Energy Engineering* 137.4 (ago. de 2015), pág. 044501. DOI: 10.1115/1.4029932.
- ¹³ S Krauter. «Increased electrical yield via water flow over the front of photovoltaic panels». en. En: *Solar Energy Materials and Solar Cells* 82.1-2 (mayo de 2004), págs. 131-137. DOI: 10.1016/j.solmat.2004.01.011.
- ¹⁴ Vivek Tomar y col. «Thermal modeling and experimental evaluation of five different photovoltaic modules integrated on prototype test cells with and without water flow». en. En: *Energy Conversion and Management* 165 (jun. de 2018), págs. 219-235. DOI: 10.1016/j.enconman.2018.03.039.
- ¹⁵ Matthew K. Smith y col. «Water Cooling Method to Improve the Performance of Field-Mounted, Insulated, and Concentrating Photovoltaic Modules». en. En: *Journal of Solar Energy Engineering* 136.3 (ago. de 2014), pág. 034503. DOI: 10.1115/1.4026466.
- ¹⁶ Azadeh Kordzadeh. «The effects of nominal power of array and system head on the operation of photovoltaic water pumping set with array surface covered by a film of water». en. En: *Renewable Energy* 35.5 (mayo de 2010), págs. 1098-1102. DOI: 10.1016/j.renene.2009.10.024.
- ¹⁷ Himanshu Sainthiya, Narendra S. Beniwal y Navneet Garg. «Efficiency Improvement of a Photovoltaic Module Using Front Surface Cooling Method in Summer and Winter Conditions». en. En: *Journal of Solar Energy Engineering* 140.6 (dic. de 2018), pág. 061009. DOI: 10.1115/1.4040238.

irrigación en regímenes en un panel FV. Esta técnica consiste en irrigar la superficie superior de un panel FV t_a minutos, dejar de irrigar t_b minutos y repetir el ciclo en una ventana de varias horas. En pruebas hechas por Osma¹⁸, encontró que esta técnica puede incrementar hasta un 10 % la energía generada diariamente por el panel FV.

2.3. IRRIGACIÓN CONTROLADA POR PROGRAMACIÓN DINÁMICA

Rojas y Caro⁸ implementaron la técnica de programación dinámica (PD) para optimizar el control de la irrigación de un panel FV, derivando en un aumento de hasta un 3.36 % de la energía generada diariamente. La técnica de irrigación por PD permite obtener un *perfil óptimo de irrigación*, el cual consiste en un vector de encendido y apagado del sistema de irrigación.

La técnica de irrigación por PD tiene una ventaja sobre la técnica de irrigación en regímenes: pueden existir distintos pares de tiempo $t_a : t_b$ en un día. En otras palabras, el perfil óptimo obtenido con la técnica de PD crea múltiples regímenes de irrigación en el día, contenidos en un único vector. Sin embargo, también presenta una desventaja que la hace inviable: no se puede implementar en la práctica.

Los perfiles óptimos solo pueden generarse después de las 6 PM, cuando ya se han recogido todos los datos de las variables básicas (irradiancia, temperatura ambiente y velocidad del viento)

En el presente trabajo, intentamos dar solución a este problema, implementando un Sistema Basado en Reglas (SBR) que puede determinar en tiempo real cuando encender o apagar el sistema de irrigación de un panel FV, a partir de la información de patrones

¹⁸ German Osma-Pinto y Gabriel Ordóñez-Plata. «Measuring the effect of forced irrigation on the front surface of PV panels for warm tropical conditions». en. En: *Energy Reports* 5 (nov. de 2019), págs. 501-514. DOI: 10.1016/j.egy.2019.04.010.

recurrentes de las variables básicas y de los perfiles óptimos.

Para comprobar los resultados obtenidos de las predicciones arrojadas por el SBR candidato, hemos utilizado el modelo térmico del panel FV propuesto por Osma en su tesis doctoral¹⁹, el cual consiste en hacer una representación del sistema termoelectrico en un sistema eléctrico, tal como se muestra en la *figura 1*.

2.4. POTENCIA GENERADA

La potencia generada por el panel fotovoltaico se describe mediante la siguiente ecuación²⁰:

$$P_{generada} = G_{inc} \cdot A_{panel_{FV}} \cdot \eta_0 (1 + \beta (T_{panel_{FV}} - 25)) \quad (1)$$

Donde:

G_{inc} → Irradiancia [W/m^2]

$A_{panel_{FV}}$ → Área del panel fotovoltaico [m^2]

η_0 → Eficiencia del panel fotovoltaico [%]

β → Coeficiente térmico del panel fotovoltaico [%/K]

$T_{panel_{FV}}$ → Temperatura de operación del panel fotovoltaico [$^{\circ}C$]

Se entiende entonces que la potencia generada depende directamente de la irradiancia

¹⁹ German Alfonso Osma Pinto. «Caracterización del desempeño de paneles FV en terrazas de edificaciones localizadas en entornos con clima tropical cálido». Tesis doct. Universidad Industrial de Santander, 2015.

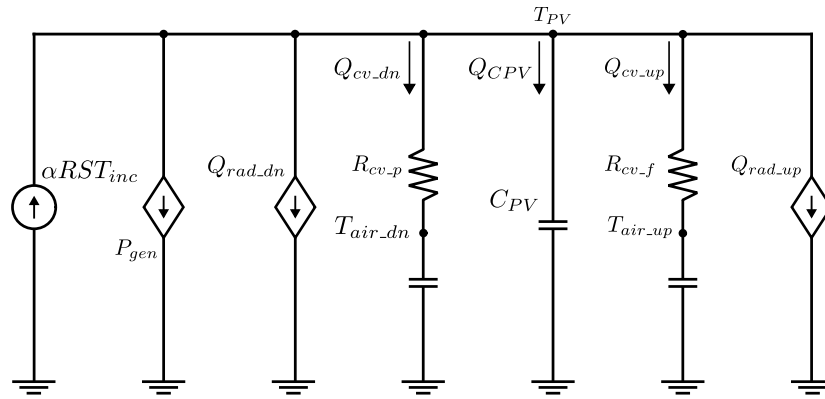
²⁰ Edgar Yesid Hernandez Cristancho, Luz Esther Quintero Sanguino y Miguel Andres Torres Romero. «Caracterizacion De La Operacion De Paneles Fotovoltaicos En Condiciones Tropicales Bajo La Influencia De Un Techo Verde. Caso Bucaramanga.» Tesis doct. Universidad Industrial de Santander, Escuela de Ingeniería Eléctrica . . . , 2016.

G_{inc} que incide en el panel FV y de su temperatura de operación $T_{panel_{FV}}$.

2.5. MODELO TÉRMICO DEL PANEL FOTOVOLTAICO

El panel FV puede representarse como una capacitancia térmica sin resistencias internas producidas por conducción, ya que se considera como un cuerpo muy delgado con la misma temperatura en toda su extensión (menos de $5[mm]$). A continuación, se listan los parámetros del modelo térmico del panel FV utilizado¹⁹.

Figura 1. Modelo térmico RC del panel FV



Adaptación de fuente: 20.

2.5.1. Puntos de temperatura En la *figura 1* se observan los siguientes nodos:

T_{PV} → Temperatura de operación del panel FV. Esta variable representa el principal nodo del modelo térmico del panel FV. Es una variable de salida desconocida.

$T_{air_{up}}$ → Temperatura del aire circulante sobre la superficie frontal del panel FV.

$T_{air_{dn}}$ → Temperatura del aire circulante debajo de la superficie posterior del panel FV.

Tanto $T_{air_{up}}$ como $T_{air_{dn}}$ son considerados sumideros térmicos con diferentes temperatu-

ras y se representan como capacitancias térmicas del panel FV con valores elevados²¹.

2.5.2. Transferencia de calor En el modelo térmico no se considera que exista transferencia de calor por conducción. En cambio, sí se considera que hay transferencia de calor por convección debido a dos procesos, representados como dos resistencias:

R_{cv_f} → Transferencia de calor por convección entre la superficie frontal del panel FV y el aire circulante del medio.

R_{cv_p} → Transferencia de calor por convección entre la superficie posterior del panel FV y el aire circulante del medio.

El aire circulante del medio en la parte frontal y posterior del panel se consideran diferentes, y se representan mediante las siguientes ecuaciones:

$$Q_{cv_{up}} = h_{cv_f} A_{panel_{FV}} (T_{panel_{FV}} - T_{air_{up}}) \quad (2)$$

$$Q_{cv_{dn}} = h_{cv_p} A_{panel_{FV}} (T_{panel_{FV}} - T_{air_{dn}}) \quad (3)$$

Donde:

$Q_{cv_{up}}$ → Transferencia de calor por convección frontal

$Q_{cv_{dn}}$ → Transferencia de calor por convección posterior

h_{cv_f} → Coeficiente de convección frontal [$W/m^2/^\circ C$]

h_{cv_p} → Coeficiente de convección posterior [$W/m^2/^\circ C$]

Además, también se considera la transferencia de calor por radiación, representada como dos fuentes de corriente dependientes:

$Q_{rad_{up}}$ → Transferencia de calor por radiación en la superficie frontal del panel FV

$Q_{rad_{dn}}$ → Transferencia de calor por radiación en la superficie posterior del panel FV

²¹ Sebastián Andrés Maggi Silva. «Modelamiento térmico de un panel fotovoltaico con disipador de calor operando en el norte de Chile». Tesis doct. Universidad de Chile, 2013.

Los procesos de transferencia de calor por radiación se describen con las siguientes expresiones:

$$Q_{rad_{up}} = \varepsilon_{PV_f} \sigma A_{panel_{FV}} \left[F_{f1} (T_{PV}^4 - T_{amb}^4) + F_{f2} (T_{PV}^4 - T_{sky\ mod}^4) \right] \quad (4)$$

$$Q_{rad_{dn}} = \varepsilon_{PV_p} \sigma A_{panel_{FV}} \left[F_{p1} (T_{PV}^4 - T_{amb}^4) + F_{p2} (T_{PV}^4 - T_{amb}^4) \right] \quad (5)$$

Donde:

ε_{PV_f} → Emitancia frontal del panel fotovoltaico (adimensional)

ε_{PV_p} → Emitancia posterior del panel fotovoltaico (adimensional)

σ → Constante de Boltzmann ($5.67 \times 10^{-8} [W/m^2/K^4]$)

T_{amb} → Temperatura ambiente [$^{\circ}C$]

$T_{sky\ mod}$ → Temperatura del cielo ajustada. El ajuste representa el nivel de nubosidad del cielo y debe ser calculado utilizando la expresión mostrada a continuación.

En las ecuaciones que expresan la transferencia de calor por radiación también están presentes los factores de visibilidad de las superficies frontal y posterior del panel FV:

F_{f1} , F_{f2} , F_{p1} y F_{p2} . Se calculan mediante las siguientes expresiones:

$$T_{sky\ mod} = (1 - \gamma) \left(0.052 \sqrt{T_{amb}^3} + \gamma T_{amb} \right) \quad (6)$$

$$F_{f1} = \frac{1 + \cos(180^{\circ} - \delta)}{2} \quad (7)$$

$$F_{f2} = \frac{1 - \cos(180^{\circ} - \delta)}{2} \quad (8)$$

$$F_{p1} = \frac{1 + \cos(180^{\circ})}{2} \quad (9)$$

$$F_{p2} = \frac{1 - \cos(180^{\circ})}{2} \quad (10)$$

Donde:

γ → Coeficiente del nivel de nubosidad

δ → Ángulo de inclinación del panel FV

2.5.3. Temperatura del panel fotovoltaico sin incluir el sistema de irrigación

La fuente de corriente presente en el modelo térmico representa la irradiación efectiva en el panel fotovoltaico. Se describen mediante las siguientes expresiones:

$$G_{in_{eff}} = \alpha RST_{inc} \quad (11)$$

$$RST_{inc} = G_{inc} A_{panel_{FV}} \quad (12)$$

Donde:

$G_{in_{eff}}$ → Irradiación efectiva en el panel fotovoltaico

α → Coeficiente de transmitancia

RST_{inc} → Irradiancia del panel fotovoltaico

G_{inc} → Radiación solar incidente

$A_{panel_{FV}}$ → Área del panel fotovoltaico

Al ubicarse en el nodo Q_{CPV} , se aplica el análisis nodal para calcular la variación de calor del panel fotovoltaico:

$$Q_{CPV} = G_{in_{eff}} - P_{gen} - Q_{rad_{dn}} - Q_{rad_{up}} - Q_{cv_{up}} - Q_{cv_{dn}} \quad (13)$$

Para determinar la temperatura de operación del panel fotovoltaico en el instante $i + 1$ se utiliza la expresión a continuación, que se encuentra en función de los flujos de calor en el instante i y de la temperatura de operación:

$$T_{PV_{i+1}} = T_{PV} + \frac{\Delta t}{C_{panel} A_{panel_{FV}}} \left(G_{in_{eff}} - P_{gen_i} - Q_{rad_{up_i}} - Q_{rad_{dn_i}} - Q_{cv_{dn_i}} - Q_{cv_{up_i}} \right) \quad (14)$$

Donde:

C_{panel} → Capacidad térmica del panel fotovoltaico [$J/m^2/K$]

Δt → Paso del tiempo [s]

2.5.4. Comportamiento térmico del agua de riego Según el modelo térmico propuesto por Osma¹⁹, la película de agua durante el proceso de irrigación obstruye la interacción de la superficie superior del panel con el entorno, dado que elimina la transferencia de calor por radiación y convección frontal. En consecuencia, se produce una corriente o flujo de calor de enfriamiento hacia el panel FV como se indica en la expresión:

$$Q_{enfriamiento} = \frac{T_{PV} - T_{agua\ riego}}{R_{riego}} \quad (15)$$

Donde:

$T_{agua\ riego} \rightarrow$ Temperatura del agua de riego [$^{\circ}C$]

$R_{riego} \rightarrow$ Resistencia de riego [$W/^{\circ}C$]

2.5.5. Temperatura del panel fotovoltaico considerando el sistema de irrigación Para calcular la variación del calor del panel fotovoltaico, se utiliza la siguiente ecuación:

$$Q_{CPV} = G_{ineff} - P_{gen} - Q_{rad_{up}} - Q_{rad_{dn}} - Q_{CV_{dn}} - Q_{CV_{up}} - Q_{enfriamiento} \quad (16)$$

La temperatura de operación del panel fotovoltaico se calcula como:

$$T_{PV_{i+1}} = T_{PV_i} + \frac{\Delta t}{C_{PV} A_{panel_{FV}}} \left(G_{ineff_i} - P_{gen_i} - Q_{rad_{up_i}} - Q_{rad_{p_i}} - Q_{cn_{dn_i}} - Q_{cn_{up_i}} - Q_{enfriamiento_i} \right) \quad (17)$$

Se asume que la temperatura del agua de riego y la temperatura del agua en la cava son iguales a la temperatura ambiente^{8 19 22}.

²² Camilo Eduardo Cortes Adarme y Juan Sebastian Jaimes Rios. «Estudio del balance térmico de los paneles fotovoltaicos instalados en la terraza del edificio de ingeniería eléctrica». Tesis doct. Universidad Industrial de Santander, 2018.

3. SISTEMA BASADO EN REGLAS

Una de las áreas más valiosas de la inteligencia artificial es la de los *sistemas basados en conocimiento*²³, usados principalmente para ayudar o reemplazar a humanos expertos a resolver problemas complejos, más conocidos como *sistemas expertos*. Un sistema experto intenta emular el proceso mental de un humano experto para tomar decisiones. Una forma fácil de encapsular y mantener el conocimiento experto es a través de *reglas* que describan dentro de un dominio específico el problema complejo que se quiere resolver, expresando los límites y restricciones de pequeñas partes del conocimiento experto usando un lenguaje declarativo.

Existen distintos formalismos para representar reglas, que varían según el contexto en el que se utilicen²⁴. Tradicionalmente se utilizan las reglas de la forma SI «condiciones»: ENTONCES «acciones»²³. Las reglas deben ser formuladas manualmente por un humano experto, que, junto a otros componentes, conforman un SBR. Sin embargo, existen dominios específicos en los que problemas complejos no pueden ser descritos por reglas creadas manualmente por humanos expertos. Este es un problema común al que se enfrenta la inteligencia artificial, por lo que se han desarrollado algoritmos que son capaces de aprender mediante distintas técnicas, recogidas bajo el paraguas del concepto de aprendizaje automático (ML, por sus siglas en inglés Machine Learning). Una técnica llamada *aprendizaje automático basado en reglas*, que agrupa distintos algoritmos que combinan el ML y los SBR para describir problemas complejos que no

²³ Peter Lucas y Linda van der Gaag. *Principles of expert systems*. International computer science series. Wokingham, England ; Reading, Mass: Addison-Wesley, 1991.

²⁴ Frederick Hayes-Roth. «Rule-based systems». En: *Communications of the ACM* 28.9 (sep. de 1985), págs. 921-932. DOI: 10.1145/4284.4286.

pueden ser descritos manualmente, ha sido desarrollada durante las últimas décadas²⁵.

3.1. APRENDIZAJE AUTOMÁTICO BASADO EN REGLAS

El aprendizaje automático basado en reglas es conceptualmente un tipo de SBR que aplica una forma de ML para automáticamente identificar reglas útiles individualmente interpretables, permitiéndoles describir de forma flexible y efectiva espacios de problemas diversos y complejos²⁶ ²⁷. Hay dos técnicas de aprendizaje automático que se pueden utilizar para este fin: *aprendizaje supervisado* y *aprendizaje por esfuerzo*. Bajo este concepto podemos encontrar algoritmos como Asociación de Minería de Reglas (ARM), los Sistemas Inmunológicos Artificiales (AIS) o los Sistemas Clasificadores de Aprendizaje (*LCS*). Nuestro trabajo presentado se enfoca en utilizar la técnica de algoritmos LCS que fueron desarrollados primariamente para el modelado, la toma de decisiones secuenciales, las clasificaciones y la predicción en un sistema adaptativo complejo.

²⁵ Stephen Frederick Smith. «A Learning System Based on Genetic Adaptive Algorithms». Tesis doct. 1980.

²⁶ J. Holmes. «A Genetics-Based Machine Learning Approach to Knowledge Discovery in Clinical Data.» En: 1996.

²⁷ Wolfgang Stolzmann. «An Introduction to Anticipatory Classifier Systems». En: *Learning Classifier Systems*. Ed. por G. Goos y col. Vol. 1813. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000, págs. 175-194. DOI: 10.1007/3-540-45027-0_9.

3.2. ALGORITMO LCS

Según Urbanowicz²⁸, un algoritmo LCS es “el nombre original de una técnica de inteligencia artificial que construye modelos de patrones inherentes en los datos a través de una búsqueda global de estructuras de patrones (reglas creadas por computación evolutiva), y aprendizaje local de utilidad de patrones (aptitud de patrones a través de aprendizaje supervisado o reforzado)”.

Los algoritmos LCS *aprenden, crean y hacen evolucionar una población de reglas* a partir de los datos que experimentan. Para que ocurra aprendizaje, el LCS debe exponerse al dominio del problema en forma de datos. Esto se puede lograr a través de experiencias previas registradas (denominado aprendizaje offline) o de forma interactiva con eventos actuales (llamado aprendizaje online). Durante el proceso de aprendizaje, el LCS debe mejorar el conjunto de reglas al incrementar el valor de reglas útiles y eliminar las reglas innecesarias. Cuando termina la fase de aprendizaje, el desempeño del modelo desarrollado se comprueba utilizando datos no vistos antes por el LCS. Las reglas del modelo pueden usarse para entender el conocimiento aprendido y para predecir la *clase* de una nueva entrada de datos²⁸. Por esta razón, podemos usar esta técnica para diseñar un SBR que pueda predecir si debe activar o no la irrigación del sistema FV en determinado momento del día.

²⁸ Ryan J. Urbanowicz y Will N. Browne. *Introduction to learning classifier systems*. eng. Springer briefs in intelligent systems. OCLC: 984753682. Berlin: Springer, 2017.

4. IMPLEMENTACIÓN DEL CASO DE ESTUDIO EN EL SBR

Ubicado en Bucaramanga, Colombia a 960 metros sobre el nivel del mar²⁹, el edificio de la Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones (E3T) en la Universidad Industrial de Santander (UIS), posee en su terraza verde un conjunto de paneles FV, además de un sistema de monitoreo que permite medir varias variables climatológicas de interés (irradiación solar, temperatura ambiente y velocidad del viento). A continuación, se hace un recorrido por el flujo de trabajo realizado para lograr la implementación, condensado en la *figura 2*. Una práctica común en el desarrollo de software es bautizar los proyectos que se realizan, por eso hemos utilizado nombres propios para cada parte de la implementación.

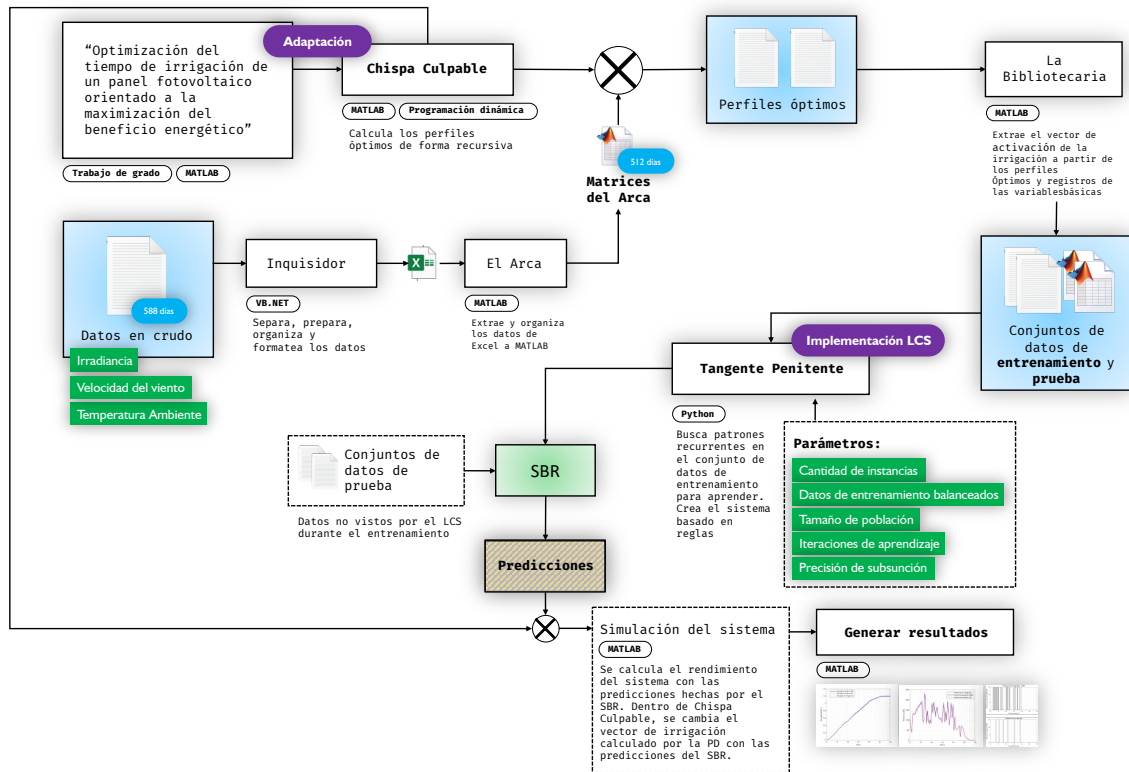
4.1. DATOS EN CRUDO

El sistema de monitoreo del edificio de la E3T consiste en un piranómetro (*Kipp & Zonen SMP-11*) para medir la irradiación solar, tres sensores de velocidad del viento (*EE671*, *EE576* y *DC-12*), termocuplas de tipo K para medir la temperatura ambiente y tres registradores de datos (*PACE XR5-SE-20 mV*, *CAMPBELL CR800X* y *OMEGA OM-CP-OCTTEMP200*).

Se nos proporcionaron registros de datos equivalentes a 588 días de las variables de interés (irradiancia, temperatura ambiente, velocidad del viento) junto a otras 35 variables extras. El rango de los datos en crudo está comprendido entre el 13 de marzo de 2018 y el 28 de enero de 2020. Estos datos en crudo se registraron con una resolución de 10

²⁹ Juan Rey y col. «Evaluación del potencial solar y eólico del campus central de la Universidad Industrial de Santander y la ciudad de Bucaramanga, Colombia.» En: *Rev.UIS.Ingenierías* 13 (dic. de 2014), págs. 49-57.

Figura 2. Diagrama del flujo de trabajo para obtener el Sistema Basado en Reglas



minutos, derivando en un banco de datos inicial de más de 3 millones de registros. Implementamos en Visual Basic para Excel (con el nombre de *Inquisidor*) un mecanismo de organización y formateo de datos para organizar los datos en crudo. El resultado es un libro de Excel con 590 hojas, donde cada hoja contiene los 143 registros de datos de las variables de cada día, las otras dos hojas son para el control.

4.2. VERIFICACIÓN DE LA INTEGRIDAD DE LOS DATOS IMPORTADOS

Los registros formateados en Excel por *El Inquisidor* son importados a Matlab como un conjunto de datos por *El Arca*. Se dio el caso en que en un par de días la resolución de captura de datos no fue de 10 minutos, o que las variables de interés de repente se hacían cero. *El Arca* se encarga de excluir esos días de nuestro *conjunto de datos*, que finalmente pasó de tener registros equivalentes de 588 días a tener 512. A la salida entrega un conjunto de datos de Matlab con los datos organizados para ser usados en la siguiente sección.

4.3. CÁLCULO DE LOS PERFILES ÓPTIMOS

Tomamos ventaja de un desarrollo previo basado en programación dinámica⁸, cuyo objetivo es generar *perfiles óptimos* de irrigación para mejorar el beneficio energético de un sistema FV, tal como el presente trabajo. En nuestra modificación bautizada *Chispa Culpable*, se utiliza el *conjunto de datos* generado por *El Arca* de forma recursiva y generar los perfiles óptimos. Un perfil óptimo es un vector que indica en qué momento debe encenderse o apagarse el sistema de irrigación, y es único para cada día. Calculamos el perfil óptimo para 512 días, lo cual tomó, en tiempo de ejecución, cerca de 4 días.

4.4. GENERACIÓN DE LOS CONJUNTOS DE DATOS DE ENTRENAMIENTO Y DE PRUEBA

Los perfiles óptimos generados por *Chispa Culpable* fueron organizados con un script de Matlab denominado *La Bibliotecaria* y exportados como un archivo de texto. Estos archivos constituyen el *conjunto de datos de entrenamiento* y el de *prueba*. En este

Tabla 1. Detalle de la estructura del conjunto de datos de entrenamiento y de prueba

Hora	Temperatura Ambiente	Velocidad del Viento	Irradiancia	Clase
⋮	⋮	⋮	⋮	⋮
6.68	20.2	0	27	0
8.66	22.4	0.4	487	1
⋮	⋮	⋮	⋮	⋮

contexto, un *conjunto de datos de entrenamiento* sirve para, valga la redundancia, entrenar al algoritmo del LCS para que pueda identificar patrones recurrentes en ellos y así, aprender. Por otro lado, un *conjunto de datos de prueba* se utiliza para validar el aprendizaje realizado por tal algoritmo y determinar si ese aprendizaje realizado es útil o no. Tanto el conjunto de datos de entrenamiento como el de prueba, tienen la misma estructura. Están formados por *instancias*, donde cada instancia tiene 5 columnas: 4 de *atributos* y 1 para la *clase*, tal como se muestra en la *tabla 1*.

Las columnas de atributos son registros de la hora y de las 3 variables de interés (temperatura ambiente, velocidad del viento e irradiancia). Estos son los datos organizados y formateados que provienen del conjunto de datos en crudo. La última columna, llamada en este contexto la *clase* o el *fenotipo*, es esa variable que tiene dos estados: 0 y 1. El estado lo determina la PD en los perfiles óptimos. El estado 0 indica que no se activa la irrigación, el estado 1 indica que sí se activa. Los atributos pueden entenderse como variables independientes y la clase es la variable dependiente.

4.5. IMPLEMENTACIÓN DEL LCS

Hemos realizado la implementación del *sistema clasificador de aprendizaje* LCS en Python para generar el sistema basado en reglas SBR, ya que es lenguaje que otorga flexibilidad y tiene tiempos de ejecución reducidos. No se utilizó ningún *toolbox* o herramienta especial para hacer la implementación en Python, únicamente funciones

primitivas del propio lenguaje. Nuestra implementación está basada en otra de código abierto desarrollada por Urbanowicz llamada *Extras*²⁸, que fue modificada para adaptarse al tipo de datos utilizados y a las especificaciones propias de nuestro trabajo. Nuestra implementación del LCS, denominada *Tangente Penitente*, consiste en 15 módulos (o también llamados en otros contextos *scripts*) encargados de tomar el *conjunto de datos de entrenamiento* para encontrar patrones recurrentes en ellos con el fin de aprender, generar y hacer evolucionar una población de reglas. Un recorrido de una instancia de entrenamiento durante el proceso de aprendizaje y generación de reglas se muestra en la *figura 2*.

4.5.1. Conjunto de datos Son los datos debidamente formateados que se le entregan al algoritmo LCS. Generalmente son registros que provienen del *ambiente* o el entorno, capturados por sensores del sistema.

4.5.2. Conjunto de población de reglas [P] Es el espacio de todas las soluciones candidatas se denomina *espacio de búsqueda*. Normalmente inicia vacío. El tamaño máximo de la población es uno de los parámetros más críticos: si es muy pequeño, la solución puede nunca encontrarse; si es muy grande, los límites de memoria del hardware o los tiempos de ejecución son demasiado extremos. Dentro del conjunto [P] se encuentran las reglas o clasificadores. Cada clasificador está compuesto de una *condición*, una *acción* (*clase, endpoint o fenotipo*) y unos parámetros asociados (*estadísticos*). Estos parámetros son actualizados en cada iteración de aprendizaje para las reglas relevantes.

En cada ciclo de aprendizaje, o iteración, una única instancia de entrenamiento pasa a través del LCS. Todo el aprendizaje y descubrimiento que ocurre en esta iteración se enfocará en esta instancia.

4.5.3. Conjunto de coincidencias [M] Al encontrar cualquier regla en [P] que concuerda con la instancia actual se forma en el conjunto [M]. Una regla coincide con una

instancia si todos los estados de atributos especificados en la regla son iguales o incluyen el estado de *atributos complementarios* en la instancia.

4.5.4. Covering Si $[M]$ está vacío (al principio de la ejecución lo está), se activa el mecanismo de *covering*, que es el responsable de la inicialización de la población de reglas al generalizar una instancia. Se generalizan los estados de atributos de la instancia y se le asigna la clase correcta. A la nueva regla se les asignan valores iniciales a sus parámetros. El pseudo-código que muestra la estrategia del covering implementada se muestra en la *figura 3*.

Figura 3. Estrategia de covering del algoritmo

```

Se requiere: instancia
 $A_{spec} = \text{aleatorio}(1, \text{limite\_atributo\_discreto})$ 
si usarCE entonces
   $i = 0$ 
  mientras  $i < A_{spec}$  hacer
    atributoObj = CE_listaOrdAtrib[i]
    agregar atributoObj a refAtrib
    si atributoObj es discretoentonces
      agregar instancia[atributoObj] a condicionRegla
    si no
      agregar nuevoRango(instancia[atributoObj]) a condicionRegla
    fin si
  fin mientras
si no
   $i = 0$ 
  mientras  $i < A_{spec}$  hacer
    atributoObj = aleatorio(atributo)
    agregar atributoObj a refAtrib
    si atributoObj es discretoentonces
      agregar nuevoRango(instancia[atributoObj]) a condicionRegla
    fin si
  fin mientras
fin si
claseRegla = claseInstancia
devolver regla

```

4.5.5. Matriz de predicciones No juega ningún papel en el entrenamiento/aprendizaje. Sólo es útil para hacer predicciones sobre datos no vistos, o para evaluar el rendimiento predictivo sobre datos de entrenamiento durante el entrenamiento.

4.5.6. Conjunto correcto e incorrecto [C] e [I] Todos los clasificadores en [M] que especifican la clase correcta forman [C], el resto forma el conjunto [I]. Para rastrear el progreso del aprendizaje la predicción del último conjunto puede ser reportada.

4.5.7. Actualización de los parámetros de las reglas Después de la formación de [M] y de [C], ciertos parámetros son actualizados para los clasificadores en [M].

4.5.8. Subsunción Si en la población existe una regla A que es más general, puede subsumir una regla B más específica, sin tener una pérdida del rendimiento general.

4.5.9. Algoritmo genético Se activa el descubrimiento de reglas por parte del algoritmo genético si la experiencia media de los clasificadores en el grupo de selección está por encima de un límite definido por el usuario. Entiéndase que la experiencia de los clasificadores es el número de instancias en las que la regla ha coincidido.

4.5.10. Eliminación Si no hay eliminación la población puede crecer ilimitadamente y se desperdicia tiempo y recursos del hardware.

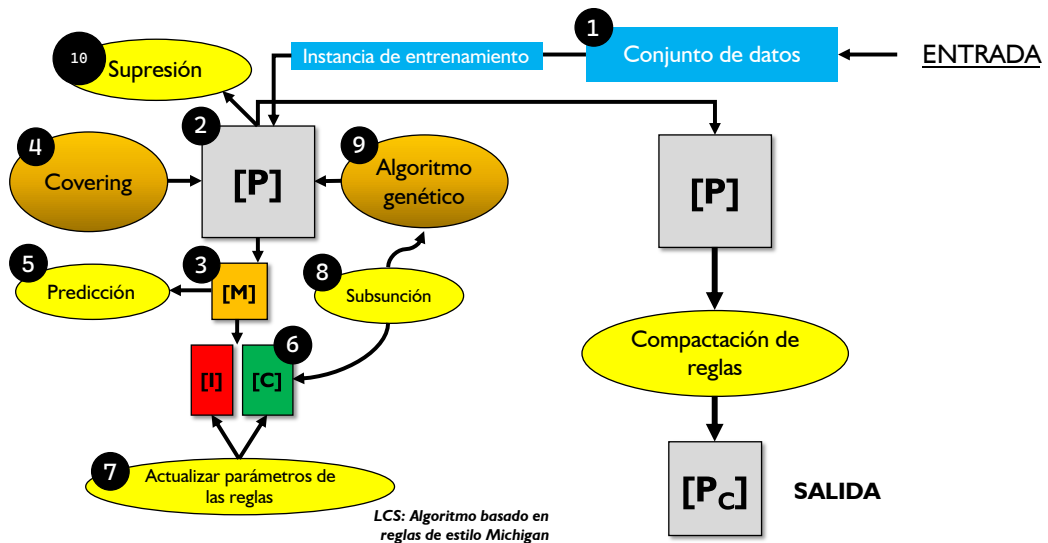
4.5.11. Compactación de reglas Al conjunto [P] se le aplica un post procesado donde se eliminan reglas que puedan ser redundantes, inexperimentadas (reglas jóvenes) o de calidad pobre.

A la salida se obtiene una población de clasificadores/reglas compactificada. Además, se incluyen dentro de la implementación, 5 Algoritmos Basados en Relief (RBA por sus siglas en inglés, *Relief-Based Algorithms*). Los RBA son una forma rápida de identificar los atributos en el conjunto de datos que pueden ser más importantes para predecir la clase.

4.6. GENERACIÓN DEL SISTEMA BASADO EN REGLAS

Ejecutamos el entrenamiento de hasta 21 SBR diferentes, ajustando parámetros del mecanismo de aprendizaje, número de iteraciones y cantidad de instancias hasta encontrar uno que satisficiera el objetivo buscado. Cada una de las pruebas realizadas consistió en la modificación y registro detallado del rendimiento de los siguientes parámetros. Así mismo, creamos un *conjunto de datos de prueba*, conformado por instancias no vistas antes por el LCS²⁸, para predecir la clase de esas instancias. Según el desempeño del SBR con estos conjuntos de datos, se decide si debe seguirse entrenando con más iteraciones y/o ajustando otros parámetros del mecanismo de aprendizaje del LCS. Estos parámetros de mecanismo se detallan en el anexo a este documento. A continuación, se listan detalles de los parámetros más relevantes que al modificarse tenían impactos notables en el SBR generado.

Figura 4. Recorrido de una instancia de entrenamiento a través de la implementación de un algoritmo LCS de estilo Michigan



Adaptado de fuente: 29.

4.6.1. Cantidad de instancias Como la resolución de los registros de datos de las variables es de 10 minutos, en el intervalo de 6AM a 5:50PM existen 72 registros de datos de las variables de interés (irradiación solar, temperatura ambiente, velocidad del viento). En la implementación de irrigación con programación dinámica los autores realizaron una interpolación de estos registros para obtener, dentro de ese mismo intervalo, 720 registros de datos y calcular los perfiles óptimos. Luego de realizar cierta cantidad de pruebas, determinamos que utilizar este número de instancias por día añadía mucho ruido, causando que el SBR arrojara una alta cantidad de predicciones incorrectas. Utilizamos entonces 72 instancias por día en el intervalo de 6AM a 6PM, equivalentes a una instancia cada 10 minutos durante 12 horas.

4.6.2. Conjunto de datos de entrenamiento balanceado Balancear el conjunto de datos de entrenamiento limitaba la cantidad de instancias totales que se podían utilizar (únicamente 57 días equivalentes a 4104 instancias), ya que el conteo de clases 0 debe ser igual al conteo de clases 1.

4.6.3. Tamaño de la población Ajustar correctamente este parámetro requiere de prueba y error, encontramos que un tamaño de población de 2000 reglas es el adecuado.

4.6.4. Cantidad de iteraciones Al utilizar los conjuntos de datos de entrenamiento con instancias de 720 datos por día, aumentar la cantidad de iteraciones luego de cierto umbral, no tenía un impacto significativo en la calidad de las predicciones. Al cambiar la cantidad de instancias de datos por día, aumentar la cantidad de iteraciones ocasiona una mejora en la fiabilidad de las predicciones obtenidas.

4.6.5. Algoritmo de conocimiento experto Existen cuatro opciones disponibles de algoritmos, los cuales son: MultiSURF, ReliefF, SURF y SURFStar. Para el SBR se tuvo en cuenta MultiSURF ya que arroja mejor rendimiento y es el algoritmo más nuevo

basado en ReliefF³⁰. Una desventaja de utilizar MultiSURF es que lleva más tiempo de ejecución comparado con las otras opciones.

4.6.6. Algoritmo de compactación de reglas Según las comparaciones mostradas en el trabajo propuesto por Urbanowicz³¹, utilizar el Filtrado Rápido de Reglas (QRF) es la manera más rápida y eficiente de compactar las reglas, sin perder rendimiento y minimizando el tamaño final de la población de reglas, lo cual es útil cuando se quiere inspeccionar manualmente el conocimiento descubierto.

4.6.7. Parámetros del SBR candidato Aunque se estableció el tamaño máximo de la población de reglas en 2000 (N), el sistema basado en reglas candidato tiene 1399 reglas, fue entrenado durante 1600000 iteraciones con un conjunto de datos no balanceado de 28800 instancias, equivalentes a registros de 400 días. Se utilizó una precisión de subsunción de 0.3, el algoritmo de conocimiento experto fue MultiSURF y el algoritmo de compactación de reglas usado fue QRF. El tiempo de ejecución utilizado para generar este SBR fue de 12.26 horas. Todos los detalles pertinentes al SBR y sus reglas pueden analizarse en los archivos anexos a este documento.

4.7. SIMULACIÓN DEL SISTEMA

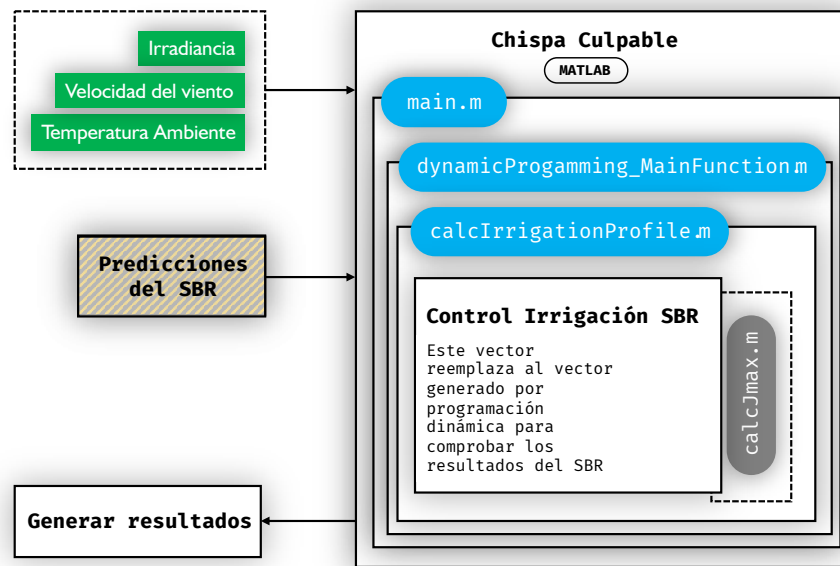
Los SBR con desempeños destacables fueron utilizados para volver a simular el sistema y evaluar realmente los resultados. Esto se logró al reemplazar el código de PD y su vector

³⁰ Igor Kononenko. «Estimating attributes: Analysis and extensions of RELIEF». En: *Machine Learning: ECML-94*. Ed. por J. G. Carbonell y col. Vol. 784. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 1994, págs. 171-182. DOI: 10.1007/3-540-57868-4_57.

³¹ Jie Tan, Jason Moore y Ryan Urbanowicz. «Rapid Rule Compaction Strategies for Global Knowledge Discovery in a Supervised Learning Classifier System». En: *Advances in Artificial Life, ECAL 2013*. MIT Press, sep. de 2013, págs. 110-117. DOI: 10.7551/978-0-262-31709-2-ch017.

de irrigación por otro vector que contiene las predicciones de irrigación arrojadas por el SBR candidato. De esta forma, *Chispa Culpable* puede calcular la potencia y energía beneficio del sistema, el perfil de control de irrigación y la temperatura en la superficie del panel. Esto se ilustra en la *figura 5*.

Figura 5. Esquemático de la estructura de un sector de los scripts y vector que fue reemplazado para calcular los resultados



Específicamente es reutilizada la implementación de las ecuaciones para calcular la potencia y energía beneficio:

$$E_{beneficio} = \int_{t_i}^{t_f} P_{beneficio} \times dt \quad (18)$$

$$P_{beneficio} = P_{generada} - P_{irrigacion} \quad (19)$$

Donde:

$t_i \rightarrow$ Temperatura inicial

$t_f \rightarrow$ Temperatura final

$E_{beneficio}$ → Energía neta en un intervalo

$P_{beneficio}$ → Potencia beneficio

$P_{generada}$ → Potencia generada por el panel FV, en función de la temperatura ambiente T_{amb} , irradiancia G_{inc} y velocidad del viento V_{viento} .

$P_{irrigacion}$ → Potencia consumida por el sistema de irrigación.

La potencia de irrigación corresponde al perfil de irrigación arrojado por las predicciones del SBR. Los resultados se utilizan para generar las gráficas y comprobar el desempeño del SBR en el sistema simulado.


5. CASO DE ESTUDIO

Se utilizaron los datos registrados de las variables de interés suministrados por la Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones E3T de la Universidad Industrial de Santander UIS. Con el SBR candidato, escogimos 7 días de forma aleatoria para comprobar su rendimiento comparado con los datos reales. Los días aleatorios fueron:

- Día 93: 14/07/2018
- Día 104: 07/08/2018
- Día 219: 22/01/2019
- Día 230: 2/02/2019
- Día 253: 25/02/2019
- Día 282: 11/04/2019
- Día 286: 23/04/2019

Estudiamos las siguientes variables de salida: Energía beneficio obtenida con programación dinámica (PD), con el sistema basado en reglas (SBR) y con el sistema sin irrigación; potencia beneficio obtenida por el sistema sin irrigación, con SBR y PD. Para graficar y comprobar resultados hemos usado MATLAB, por la familiaridad de nosotros con el lenguaje y la facilidad para generar y exportar las gráficas.

Figura 6. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 93.




5.1. Análisis y gráficas del día 93

En la *figura 6* se muestra el comportamiento de las variables de entrada, la irradiancia alcanza su pico máximo de casi $1000 \frac{W}{m^2}$ alrededor de las 9AM, cuando la velocidad del viento es cero y la temperatura ambiente empieza a ascender. En la *figura 7* se aprecia cortos intervalos en los que la potencia beneficio obtenida con el SBR es mayor que la obtenida con la PD, presumiblemente en instantes donde la irradiancia tiene sus picos.

El corto momento de después de las 8AM es cuando se aprecia la mayor diferencia de

energía beneficio, que es cuando ocurre el primer pico de irradiancia del día, después de ese instante hay un valle y luego un pico mayor. Al final del día, la energía beneficio alcanzada con el SBR es 1.89% menor a la obtenida con PD, tal como se observa en la *figura 8*.

Figura 7. Potencia beneficio SBR vs PD vs sin irrigación, día 93.



En la *figura 9*, se presenta mayor potencia de irrigación consumida por el SBR con respecto a la PD, el mayor rango de consumo en SBR es en el intervalo de 7AM a 9AM.

Figura 8. Energía beneficio SBR vs PD vs sin irrigación, día 93.



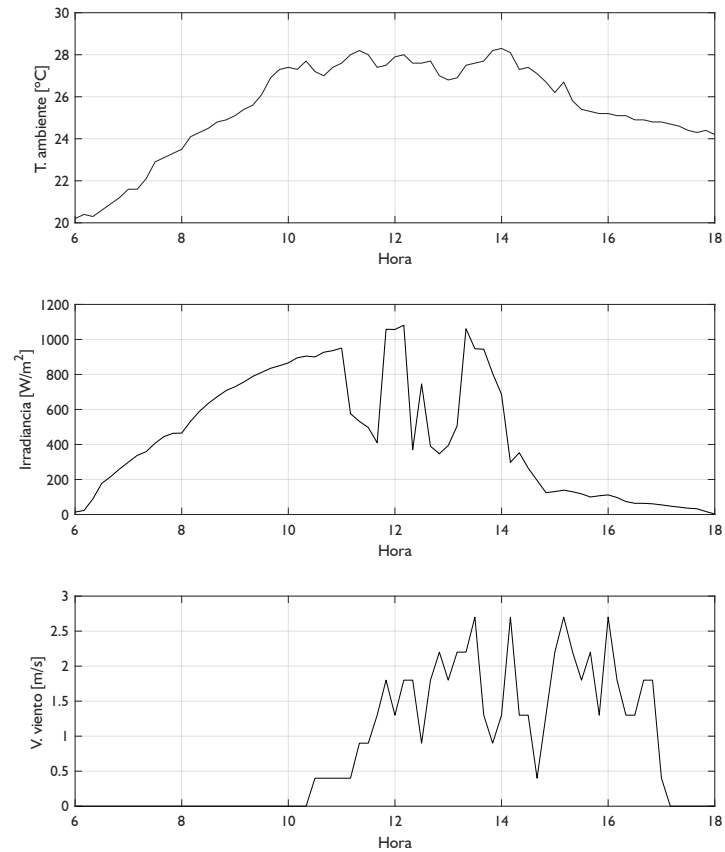


Figura 9. Potencia de irrigación SBR vs PD, día 93.




5.2. Análisis y gráficas del día 104

Figura 10. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 104.



En la *figura 10* se observa los perfiles de las variables de interés, con muy pocos picos en comparación con otros días. La irradiancia alcanza su valor máximo de $1000 \frac{W}{m^2}$ alrededor del mediodía y luego poco después de la 1PM. En la *figura 12* se observa que la energía beneficio obtenida con el SBR es 1.44% menor que la alcanzada con PD. En la *figura 11* se aprecian instantes en que la potencia beneficio obtenida con PD presenta pequeños valles que no se ven en la potencia beneficio obtenida con el SBR.

Figura 11. Potencia beneficio SBR vs PD vs sin irrigación, día 104.



En la *figura 13* se ilustra la potencia de irrigación consumida por el SBR y la PD. Los momentos del día que el SBR entró en operación el sistema de irrigación se concentran principalmente entre las 8:15AM y 11:00AM.

Figura 12. Energía beneficio SBR vs PD vs sin irrigación, día 104.


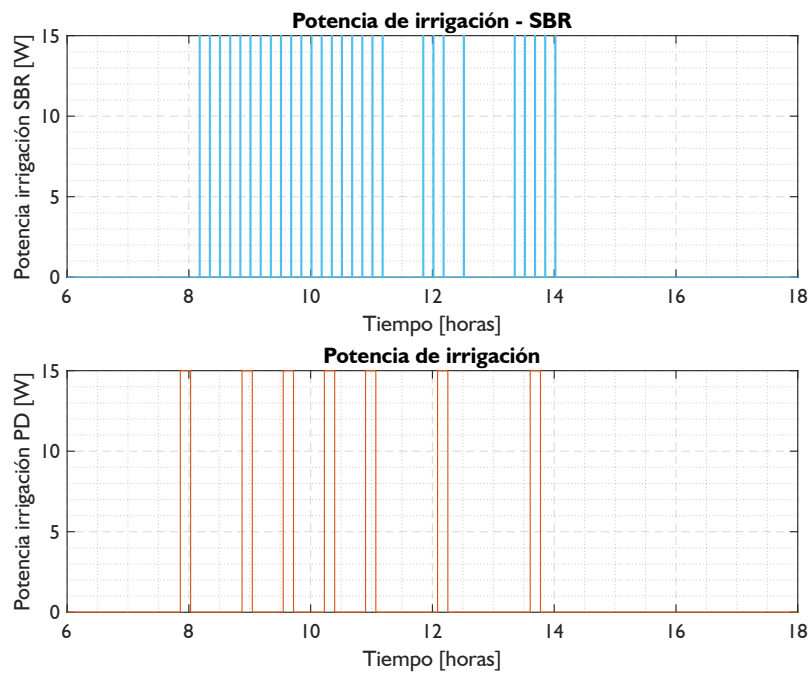
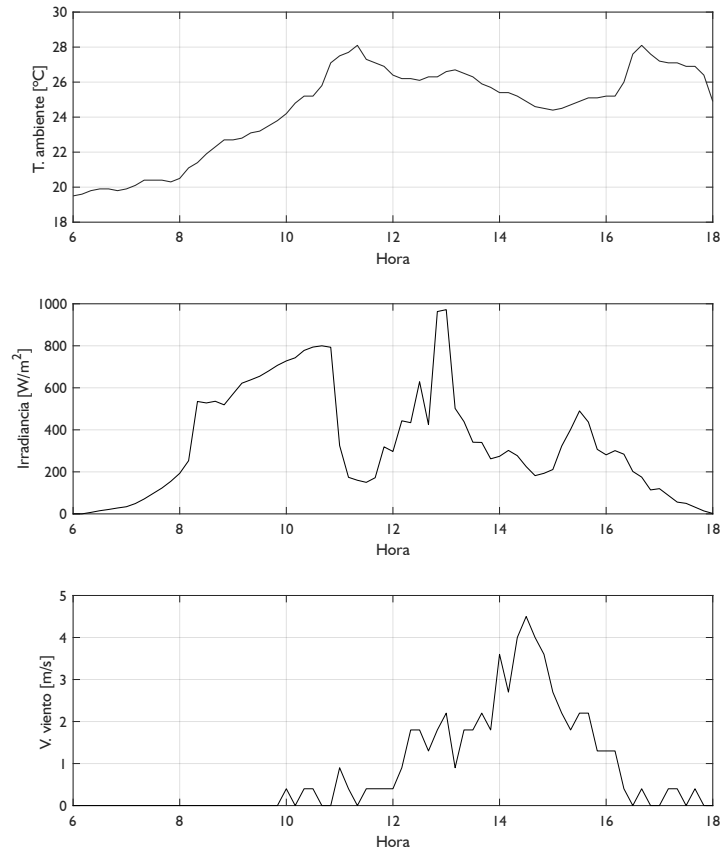


Figura 13. Potencia de irrigación SBR vs PD, día 104.



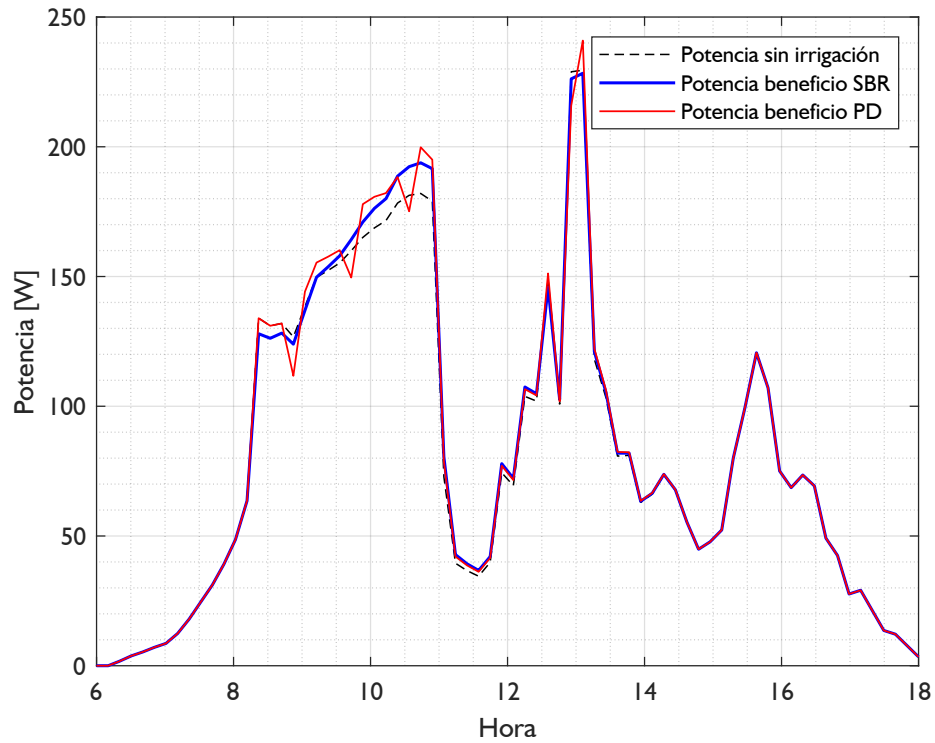
5.3. Análisis y gráficas del día 219

Figura 14. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 219.



La *figura 14* muestra el comportamiento de las variables de entrada. El pico de irradiancia de casi $1000 \frac{W}{m^2}$ se alcanza alrededor de la 1PM. En la *figura 15* se ilustra que la potencia beneficio obtenida por el SBR tiene variaciones significativas en el rango de las 8:00AM a 10:30AM con respecto a la PD. Es interesante que, en el resto del día, ambas curvas se comportan practicamente igual, derivando en el resultado destacable mostrado en la *figura 16*, donde la energía obtenida es aproximadamente la misma utilizando el SBR candidato y la PD.

Figura 15. Potencia beneficio SBR vs PD vs sin irrigación, día 219.



En la *figura 17* se observa que en las horas de las 8:00AM y 11:00AM se presenta la mayor potencia consumida por el sistema de irrigación del SBR. Es interesante destacar que en ese intervalo es cuando la curva de potencia beneficio obtenido por el SBR supera por instantes a la potencia beneficio obtenida con la PD.

Figura 16. Energía beneficio SBR vs PD vs sin irrigación, día 219.






Figura 17. Potencia de irrigación SBR vs PD, día 219.



5.4. Análisis y gráficas del día 230


Figura 18. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 230.



En la *figura 18* se observa el comportamiento de las variables de interés. El pico de irradiancia de $1000 \frac{W}{m^2}$ se alcanza poco antes de la 1PM, cuando la velocidad del viento es poco menor a 2 m/s . En la *figura 20* se aprecia que la energía beneficio obtenida en el SBR es menor que la energía del sistema sin irrigación y la energía obtenida con PD, es decir, se está perdiendo 0.64 % de energía respecto a la energía obtenida por el sistema sin irrigación. En la *figura 19* se aprecia que la potencia beneficio obtenida con el SBR es menor que la potencia del sistema sin irrigación en el intervalo de 1PM a

2PM. También hay varios instantes en que la potencia beneficio obtenida con SBR es un poco menor que la potencia beneficio obtenida con la PD, solo hay instantes muy puntuales en que sucede el caso contrario.

Figura 19. Potencia beneficio SBR vs PD vs sin irrigación, día 230.



En la *figura 21*, se ilustra la poca potencia consumida por el SBR en el rango de operación entre las 12:15 del mediodía y 1:50PM.

Figura 20. Energía beneficio SBR vs PD vs sin irrigación, día 230.


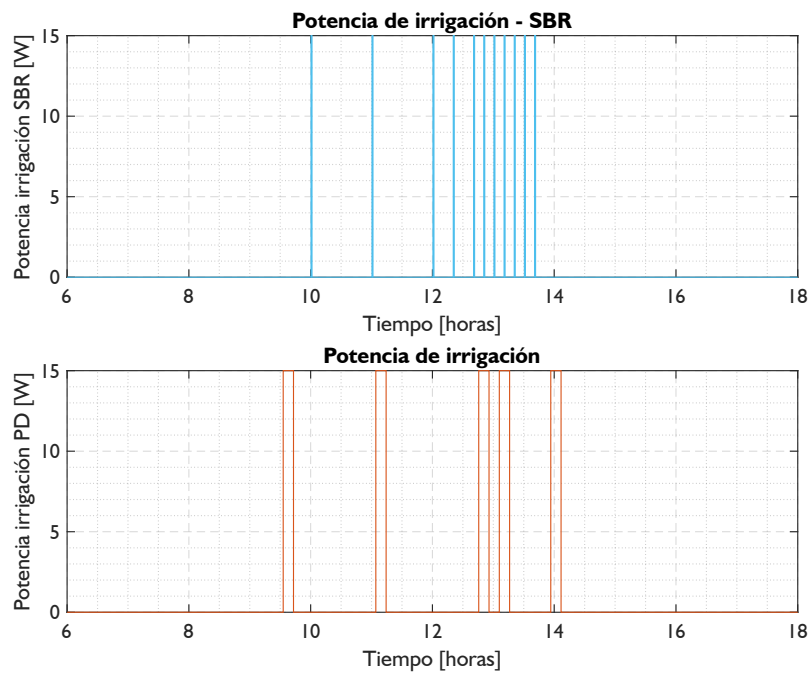
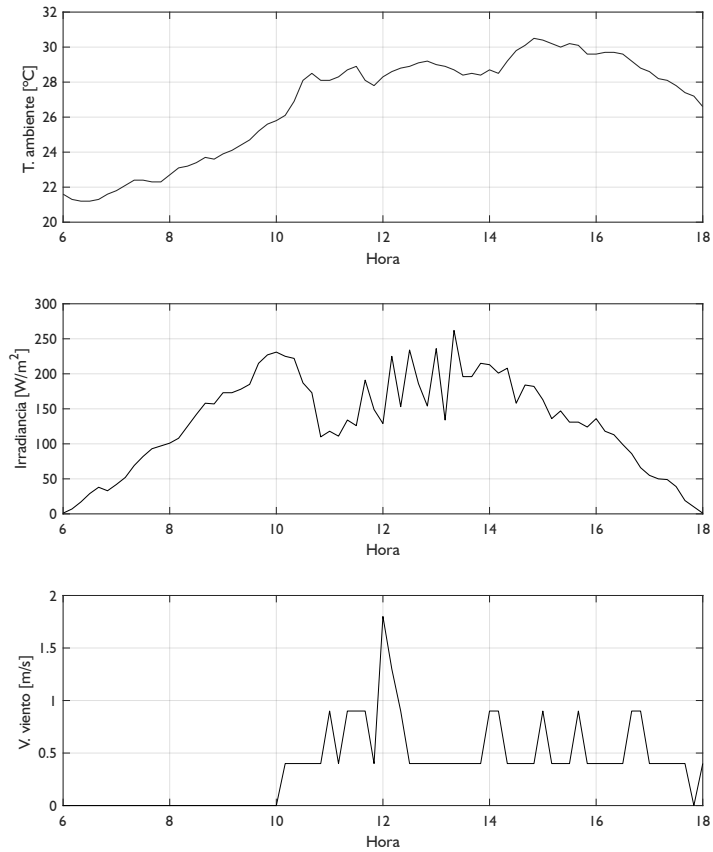


Figura 21. Potencia de irrigación SBR vs PD, día 230.




5.5. Análisis y gráficas del día 253

Figura 22. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 253.



En la *figura 22* se muestran las variables de entrada. Debe destacarse que en este día el pico de irradiación solar es alcanzado poco después de la 1PM y es un poco mayor a $250 \frac{W}{m^2}$, probablemente fue un día nublado o lluvioso. En la *figura 24* se aprecia que la energía beneficio para los tres casos es la misma y es significativamente inferior a la energía obtenida en otros días con mayor irradiancia. En la *figura 23* se observa la causa del comportamiento de la curva mostrada en la figura de la energía beneficio, la potencia beneficio obtenida en los tres casos es la misma, no hay variación alguna.

Figura 23. Potencia beneficio SBR vs PD vs sin irrigación, día 253.



En la *figura 25* se comprueba la causa real del comportamiento de las curvas de energía y potencia beneficio. Tanto el SBR como la PD consideran que no es necesaria activar la irrigación en ningun momento del día, lo cual es comportamiento deseable, ya que si es activado el sistema de irrigación se produciría un gasto innecesario de potencia para activarlo.

Figura 24. Energía beneficio SBR vs PD vs sin irrigación, día 253.

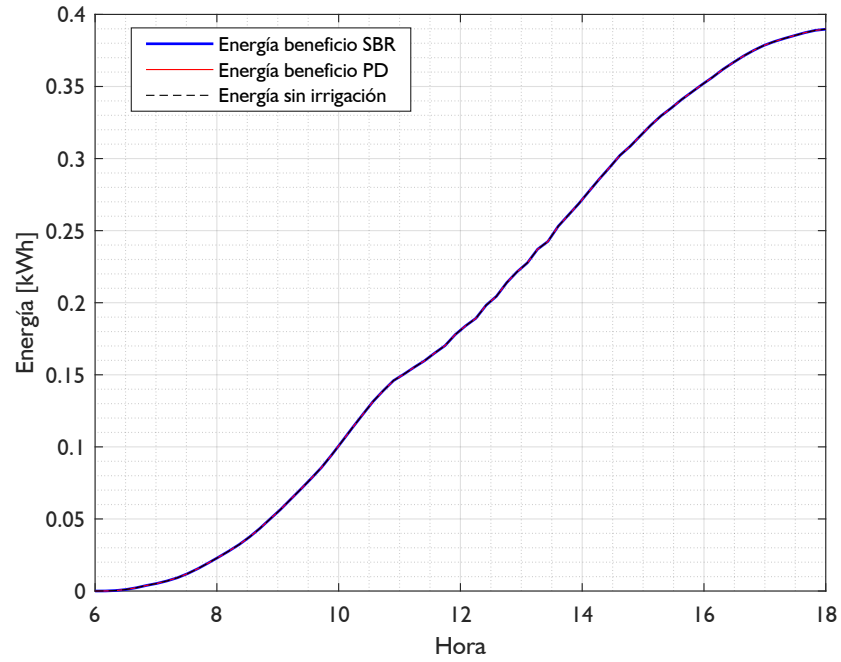
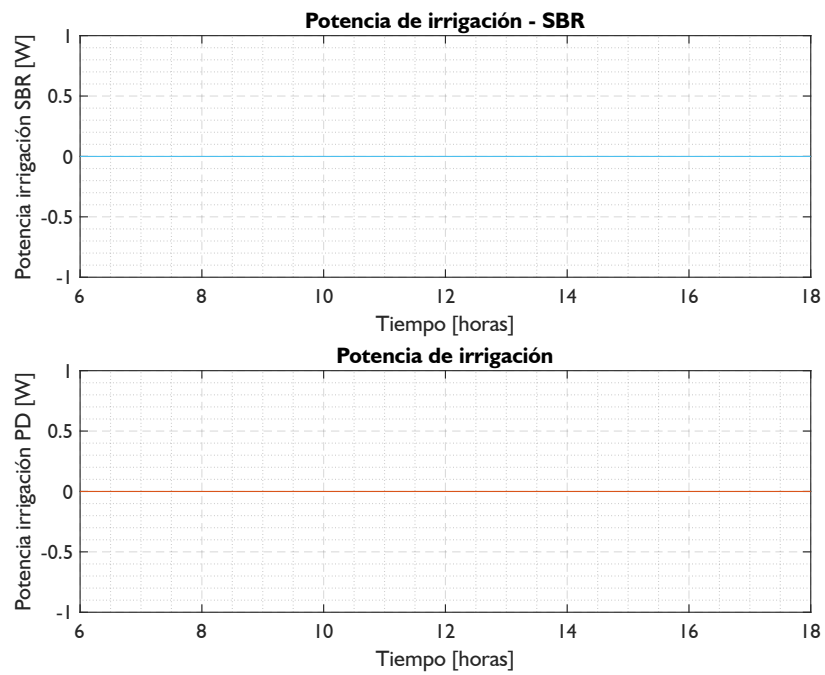



Figura 25. Potencia de irrigación SBR vs PD, día 253.




5.6. Análisis y gráficas del día 282

Figura 26. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 282.



En la *figura 26* se observa el comportamiento de las variables de interés. La irradiancia alcanza su pico máximo en varios instantes del día, poco antes de mediodía y poco antes de la 1PM. Es interesante destacar también que la temperatura máxima alcanzada en el día es de poco más de 27 °C. En la *figura 28*, la energía beneficio obtenida con el SBR es 1.76 % menor respecto a la que se alcanza con PD. En la *figura 27* se aprecia que la potencia beneficio obtenida con PD es mayor a la potencia beneficio obtenida con SBR en ciertos instantes. Esos instantes coinciden con los picos de irradiancia.

Figura 27. Potencia beneficio SBR vs PD vs sin irrigación, día 282.



En la *figura 29* se ilustra que en las horas de las 11:00AM a las 3:00PM se presenta la mayor potencia consumida por activación del sistema de irrigación del SBR con respecto a la consumida por la PD.

Figura 28. Energía beneficio SBR vs PD vs sin irrigación, día 282.






Figura 29. Potencia de irrigación SBR vs PD, día 282.




5.7. Análisis y gráficas del día 286

Figura 30. Perfil de irradiancia, temperatura ambiente y velocidad del viento, día 286.



En la *figura 30* se muestran las variables de entrada, donde se destaca el comportamiento de la irradiancia, que tiene su primer pico de casi los $1000 \frac{W}{m^2}$ poco después de las 10AM y luego otra vez poco antes de la 1PM. Entre las 10AM y la 1PM se observa un valle interesante que desciende a menos de la mitad de la irradiancia máxima alcanzada. En la *figura 32* la energía beneficio alcanzada por el SBR es de 1.24 % con respecto a la obtenida por PD. En la *ffigura 31*, la potencia beneficio del SBR se aproxima a la potencia beneficio obtenida con PD en el rango de las 10:15AM y 12:15PM.

Figura 31. Potencia beneficio SBR vs PD vs sin irrigación, día 286.



En la *figura 33* se observa que en los intervalos de las 8AM a 8:30AM, la potencia consumida por activar el sistema de irrigación debida al SBR es mayor a la consumida en la PD, y en el rango de 9AM a 10:30AM.

Figura 32. Energía beneficio SBR vs PD vs sin irrigación, día 286.

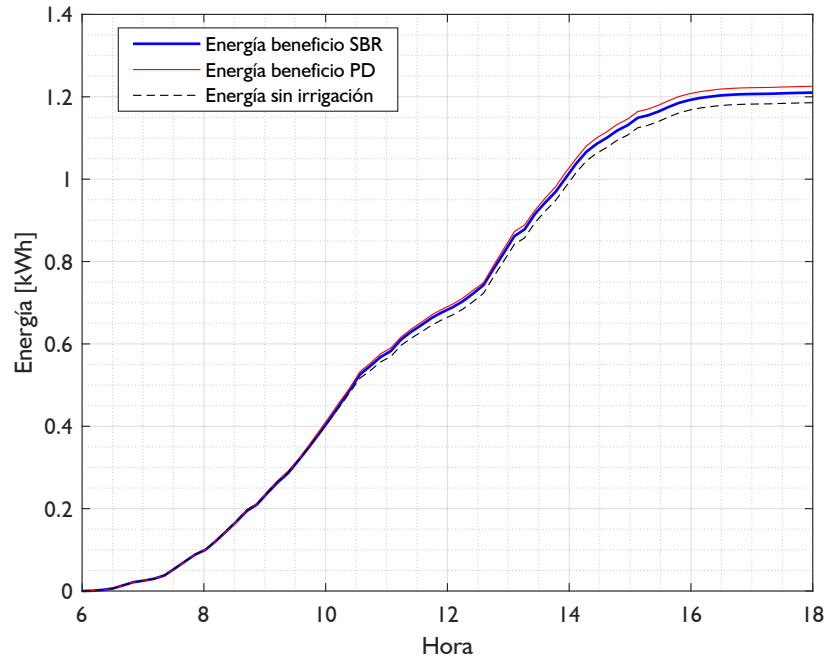
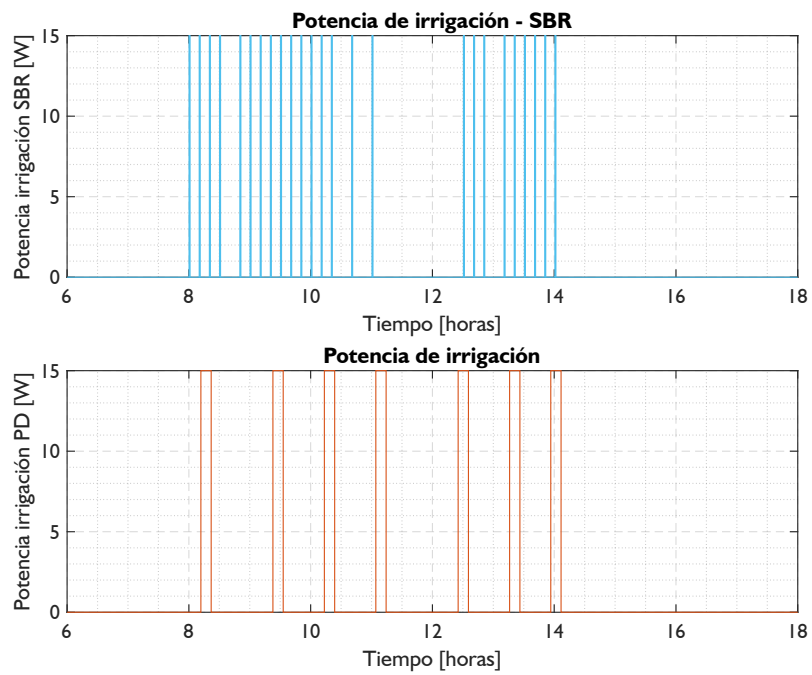


Figura 33. Potencia de irrigación SBR vs PD, día 286.



BIBLIOGRAFÍA

- Adarme, Camilo Eduardo Cortes y Juan Sebastian Jaimes Rios. «Estudio del balance térmico de los paneles fotovoltaicos instalados en la terraza del edificio de ingeniería eléctrica». Tesis doct. Universidad Industrial de Santander, 2018 (vid. pág. 26).
- Caro Padilla, Miguel Ángel y Diego Fernando Rojas Luna. *Optimización del tiempo de irrigación de un panel fotovoltaico orientado a la maximización del beneficio energético*. Trabajo de Grado para optar al título de Ingeniero Electricista de la Universidad Industrial de Santander. 2019 (vid. págs. 17, 20, 26, 32).
- Dubey, Swapnil, Jatin Narotam Sarvaiya y Bharath Seshadri. «Temperature Dependent Photovoltaic (PV) Efficiency and Its Effect on PV Production in the World – A Review». en. En: *Energy Procedia* 33 (2013), págs. 311-321. DOI: 10.1016/j.egypro.2013.05.072 (vid. pág. 15).
- Gaillard, Leon y col. «Experimental evaluation of a naturally ventilated PV double-skin building envelope in real operating conditions». en. En: *Solar Energy* 103 (mayo de 2014), págs. 223-241. DOI: 10.1016/j.solener.2014.02.018 (vid. pág. 15).
- Habibollahi, M., M. Ameri y S. H. Mansouri. «Efficiency Improvement of Photovoltaic Water Pumping Systems by Means of Water Flow Beneath Photovoltaic Cells Surface». en. En: *Journal of Solar Energy Engineering* 137.4 (ago. de 2015), pág. 044501. DOI: 10.1115/1.4029932 (vid. pág. 19).
- Hayes-Roth, Frederick. «Rule-based systems». En: *Communications of the ACM* 28.9 (sep. de 1985), págs. 921-932. DOI: 10.1145/4284.4286 (vid. pág. 27).

- Hernandez Cristancho, Edgar Yesid, Luz Esther Quintero Sanguino y Miguel Andres Torres Romero. «Caracterizacion De La Operacion De Paneles Fotovoltaicos En Condiciones Tropicales Bajo La Influencia De Un Techo Verde. Caso Bucaramanga.» Tesis doct. Universidad Industrial de Santander, Escuela de Ingeniería Eléctrica . . . , 2016 (vid. pág. 21).
- Holmes, J. «A Genetics-Based Machine Learning Approach to Knowledge Discovery in Clinical Data.» En: 1996 (vid. pág. 28).
- Hussien, Hashim A, Ali H Numan y Abdulmunem R Abdulmunem. «Improving of the photovoltaic / thermal system performance using water cooling technique». En: *IOP Conference Series: Materials Science and Engineering* 78 (abr. de 2015), pág. 012020. DOI: 10.1088/1757-899X/78/1/012020 (vid. págs. 15, 16, 18).
- Kononenko, Igor. «Estimating attributes: Analysis and extensions of RELIEF». En: *Machine Learning: ECML-94*. Ed. por J. G. Carbonell y col. Vol. 784. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 1994, págs. 171-182. DOI: 10.1007/3-540-57868-4_57 (vid. pág. 39).
- Kordzadeh, Azadeh. «The effects of nominal power of array and system head on the operation of photovoltaic water pumping set with array surface covered by a film of water». en. En: *Renewable Energy* 35.5 (mayo de 2010), págs. 1098-1102. DOI: 10.1016/j.renene.2009.10.024 (vid. pág. 19).
- Krauter, S. «Increased electrical yield via water flow over the front of photovoltaic panels». en. En: *Solar Energy Materials and Solar Cells* 82.1-2 (mayo de 2004), págs. 131-137. DOI: 10.1016/j.solmat.2004.01.011 (vid. pág. 19).

- Lucas, Peter y Linda van der Gaag. *Principles of expert systems*. International computer science series. Wokingham, England ; Reading, Mass: Addison-Wesley, 1991 (vid. pág. 27).
- Maggi Silva, Sebastián Andrés. «Modelamiento térmico de un panel fotovoltaico con disipador de calor operando en el norte de Chile». Tesis doct. Universidad de Chile, 2013 (vid. pág. 23).
- Molki, Arman. «Temperature effect on photovoltaic cells». En: *Physics Education* 46.5 (sep. de 2011), págs. 523-525. DOI: 10.1088/0031-9120/46/5/F08 (vid. pág. 15).
- Nižetić, S., E. Giama y A.M. Papadopoulos. «Comprehensive analysis and general economic-environmental evaluation of cooling techniques for photovoltaic panels, Part II: Active cooling techniques». en. En: *Energy Conversion and Management* 155 (ene. de 2018), págs. 301-323. DOI: 10.1016/j.enconman.2017.10.071 (vid. págs. 18, 19).
- Nižetić, S. y col. «Water spray cooling technique applied on a photovoltaic panel: The performance response». en. En: *Energy Conversion and Management* 108 (ene. de 2016), págs. 287-296. DOI: 10.1016/j.enconman.2015.10.079 (vid. pág. 19).
- Odeh, Saad y Masud Behnia. «Improving Photovoltaic Module Efficiency Using Water Cooling». en. En: *Heat Transfer Engineering* 30.6 (mayo de 2009), págs. 499-505. DOI: 10.1080/01457630802529214 (vid. págs. 18, 19).
- Olchowik, JM y col. «Influence of temperature on the efficiency of monocrystalline silicon solar cells in the South-eastern Poland conditions». En: *Materials Science-Poland* 24.4 (2006), págs. 1127-1132 (vid. pág. 15).

- Osma-Pinto, German y Gabriel Ordóñez-Plata. «Measuring the effect of forced irrigation on the front surface of PV panels for warm tropical conditions». en. En: *Energy Reports* 5 (nov. de 2019), págs. 501-514. DOI: 10.1016/j.egy.2019.04.010 (vid. pág. 20).
- Osma Pinto, German Alfonso. «Caracterización del desempeño de paneles FV en terrazas de edificaciones localizadas en entornos con clima tropical cálido». Tesis doct. Universidad Industrial de Santander, 2015 (vid. págs. 21, 22, 26).
- Pinto, German Alfonso Osma. «Uso racional de la energía a partir del diseño de aplicaciones sostenibles en el edificio eléctrica II de la Universidad Industrial De Santander». En: 2013 (vid. pág. 15).
- Rey, Juan y col. «Evaluación del potencial solar y eólico del campus central de la Universidad Industrial de Santander y la ciudad de Bucaramanga, Colombia.» En: *Rev.UIS.Ingenierías* 13 (dic. de 2014), págs. 49-57 (vid. pág. 30).
- Sainthiya, Himanshu, Narendra S. Beniwal y Navneet Garg. «Efficiency Improvement of a Photovoltaic Module Using Front Surface Cooling Method in Summer and Winter Conditions». en. En: *Journal of Solar Energy Engineering* 140.6 (dic. de 2018), pág. 061009. DOI: 10.1115/1.4040238 (vid. pág. 19).
- Smith, Matthew K. y col. «Water Cooling Method to Improve the Performance of Field-Mounted, Insulated, and Concentrating Photovoltaic Modules». en. En: *Journal of Solar Energy Engineering* 136.3 (ago. de 2014), pág. 034503. DOI: 10.1115/1.4026466 (vid. pág. 19).
- Smith, Stephen Frederick. «A Learning System Based on Genetic Adaptive Algorithms». Tesis doct. 1980 (vid. pág. 28).

- Stolzmann, Wolfgang. «An Introduction to Anticipatory Classifier Systems». En: *Learning Classifier Systems*. Ed. por G. Goos y col. Vol. 1813. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000, págs. 175-194. DOI: 10.1007/3-540-45027-0_9 (vid. pág. 28).
- Tan, Jie, Jason Moore y Ryan Urbanowicz. «Rapid Rule Compaction Strategies for Global Knowledge Discovery in a Supervised Learning Classifier System». En: *Advances in Artificial Life, ECAL 2013*. MIT Press, sep. de 2013, págs. 110-117. DOI: 10.7551/978-0-262-31709-2-ch017 (vid. pág. 39).
- Tomar, Vivek y col. «Thermal modeling and experimental evaluation of five different photovoltaic modules integrated on prototype test cells with and without water flow». en. En: *Energy Conversion and Management* 165 (jun. de 2018), págs. 219-235. DOI: 10.1016/j.enconman.2018.03.039 (vid. pág. 19).
- Universidad Industrial de Santander y col. «Mejoramiento del desempeño de paneles fotovoltaicos a partir de la irrigación forzada de la superficie superior». En: *Revista UIS Ingenierías* 16.2 (sep. de 2017), págs. 161-172. DOI: 10.18273/revuin.v16n2-2017015 (vid. pág. 15).
- Urbanowicz, Ryan J. y Will N. Browne. *Introduction to learning classifier systems*. eng. Springer briefs in intelligent systems. OCLC: 984753682. Berlin: Springer, 2017 (vid. págs. 29, 34, 37, 69).

ANEXOS

Anexo A. Determinación de los parámetros del mecanismo de aprendizaje del LCS

Los parámetros necesarios se presentan en la tabla 1, La mayoría de los valores de parámetros predeterminados son algo arbitrarios basado en lo que se ha usado típicamente en otros algoritmos LCS. Los parámetros no reflejan un conjunto óptimo de ejecución para un conjunto de datos determinado²⁸.

Parámetros del SBR, tomado y adaptado de 28.

Nombre	Significado
archivoEntrenamiento	Especifica la ruta o nombre del archivo para el conjunto de datos de entrenamiento.
archivoPrueba	Define la ruta o nombre del archivo para el conjunto de datos de prueba.
nombreArchivoSalida	Especifica la ruta del archivo o nombre para la salida estándar.
datosOffline	Define datos fuera de línea.
validacionCruzadaInterna	Permite al usuario realizar análisis de validación cruzada internamente.
semillaAleatoria	Permite al usuario establecer una semilla aleatoria constante.
etiquetaIDInstancia	Especifica el encabezado de la columna del ID de instancia.
etiquetaFenotipo	Etiqueta del fenotipo.

Tabla 2 continuación de la página anterior

Nombre	Significado
limiteAtributoDiscreto	Especifica el número de estados de atributo únicos.
etiquetaDatosFaltantes	Permite la designación única para un punto de datos que faltan en un entrenamiento dado.
frecuenciaSeguimiento	Especifica la frecuencia de seguimiento del rendimiento de aprendizaje.
iteracionesAprendizaje	Iteraciones de aprendizaje.
salidaResumen	Genera un resumen de estadísticas de población archivo.
salidaPoblacion	Salida de la población.
salidaAttCoOccur	Generar archivo de texto que clasifique los pares superiores de atributos.
salidaPrediccionesPrueba	Predicciones para todas las instancias en el conjunto de datos de prueba cargado.
N	Especifica el tamaño máximo de la población.
nu	Define la potencia a la que se eleva la precisión al calcular clasificador de fitness (aptitud).
chi	Especifica la probabilidad para descubrir nuevos descendientes clasificadores.
epsilon	Generaliza un estado de atributo dentro de un clasificador descendiente.
theta_GA	Umbral aplicado a la activación del algoritmo genético.
theta_del	Umbral aplicado al mecanismo de eliminación.
theta_sub	Umbral aplicado al mecanismo de subsunción.

Tabla 2 continuación de la página anterior

Nombre	Significado
acc_sub	Umbral de precisión aplicado al mecanismo de subsunción.
beta	Actualiza el promedio correcto.
delta	Parámetro de eliminación aplicado al cálculo de voto para cada clasificador.
aptitudInicial	Especifica la aptitud inicial dada a un nuevo clasificador.
reduccionAptitud	Reducción de aptitud inicial a la descendencia.
theta_sel	Fracción del conjunto correcto.
RSL_Override	Anulación opcional del límite de especificidad de la regla.
hacerSubsuncion	Especifica si la subsunción está activada o no.
metodoSeleccion	Método de selección para clasificadores de padres.
hacerSeguimientoAtributos	Mecanismo de seguimiento de atributos.
hacerFeedbackAtributos	Mecanismo de retroalimentación de atributo.
usarConocimientoExperto	Conocimiento experto que cubre el mecanismo.
generacionCEEexterno	Conocimiento experto generado por el algoritmo.
nombreArchivoSalidaCE	Archivo de prefijo para el archivo de puntuación.
algoritmoFiltro	Especifica el algoritmo de peso para generar/borrar el conocimiento experto.
porcentajeTurf	Porcentaje de atributos.

Tabla 2 continuación de la página anterior

Nombre	Significado
vecinosRelieff	Número de ‘vecinos’ utilizado en el cálculo de puntuaciones de ReliefF.
fraccionMuestreoRelieff	Proporciona el número de iteraciones que debe completar el algoritmo.
soloPuntajesCE	Ejecuta uno de los algoritmos de atributos.
hacerCompactacionReglas	Compactación de reglas.
soloCR	Ejecutar estrategias de compactación
metodoCompactacionReglas	Método de compactación de reglas.
hacerReinicioPoblacion	Clasificación de salida de la población.
rutaReinicioPoblacion	Numero de iteración para el archivo de población.

Anexo B. Software utilizado para generar el SBR

Estos anexos incluyen todo el software utilizado para generar el Sistema Basado en Reglas. Pueden visualizarlos en la Base de Datos de la Biblioteca UIS.

Se incluye el software en Python llamado *Tangente Penitente*, que consiste en el Sistema Clasificador de Aprendizaje LCS; el software en MATLAB llamado *Chispa Culpable*, que es una adaptación del trabajo de Caro y Rojas para generar perfiles óptimos basado en programación dinámica; junto a los demás componentes necesarios para asegurar la organización y la integridad de los datos, tal como se muestra en la figura2.