

TESIS DOCTORAL



REDES DE SENSORES PARA LA PREDICCIÓN
SOLAR A CORTO PLAZO EN EL MARCO DE LAS
MICROGRIDS Y SMARTCITIES

Manuel Jesús Espinosa Gavira

Directores:
Agustín Agüera Pérez
Juan José González de la Rosa

Universidad de Cádiz
Departamento en Ingeniería en Automática, Electrónica,
Arquitectura y Redes de Computadores
Algeciras, December 9, 2022

Agustín Agüera Pérez, Profesor Contratado Doctor de la Universidad de Cádiz perteneciente al departamento en Ingeniería en Automática, Electrónica, Arquitectura y Redes de computadores, en calidad de Director de tesis, AUTORIZA la presentación a trámite de la Tesis de D. Manuel Jesús Espinosa Gavira, titulada “Redes De Sensores Para La Predicción Solar a Corto Plazo en El Marco De Las Microgrids Y Smartcities”.

AGUERA
PEREZ
AGUSTIN -
44043728Q

Firmado digitalmente por AGUERA
PEREZ AGUSTIN - 44043728Q
Nombre de reconocimiento (DN):
c=ES,
serialNumber=IDCES-44043728Q,
givenName=AGUSTIN,
sn=AGUERA PEREZ, cn=AGUERA
PEREZ AGUSTIN - 44043728Q
Fecha: 2022.12.09 16:31:52 +01'00'

Fdo.: Agustín Agüera Pérez

Agradecimientos

Llegado este momento, me gustaría agradecer a los doctores Agustín Agüera Pérez y Juan José González de la Rosa su invaluable labor de orientación, apoyo y ayuda. También quisiera agradecer a todos los miembros del grupo de investigación *Instrumentación Computacional y Electrónica Industrial (PAIDI-TIC-168)* la ayuda prestada.

Agradezco a los responsables del Programa de Doctorado en Ingeniería Energética y Sostenible por su asesoramiento y facilidades ofrecidas.

Por último y no menos importante, agradecer el apoyo a todas esas personas que en el ámbito personal han estado ahí durante esta etapa: familiares, pareja y amigos.

La presente Tesis doctoral con título: “Redes De Sensores Para La Predicción Solar a Corto Plazo en El Marco De Las Microgrids Y Smartcities” cumple los requisitos necesarios para ser presentada en la modalidad Tesis por Compendio de Publicaciones, según recoge el Reglamento UCA/CG06/2012, del 27 de junio de 2012.

1. Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, Juan José González de la Rosa, José Carlos Palomares-Salas y José María Sierra-Fernández. An on-line low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV system. *Sensors* 2018, 1424-8220. 10.3390/s18103405.
2. Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José-Carlos Palomares-Salas, Juan-José González-de-la-Rosa, José-María Sierra-Fernández, Olivia Florencias-Olivero. Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method. *Solar Energy* 2020, 1471-1257. 10.1016/j.solener.2020.03.081.
3. Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José María Sierra-Fernández, Juan José González de-la-Rosa, José Carlos Palomares-Salas y Olivia Florencias-Olivero. Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring. *Sensors* 2022, 1424-8220. 10.3390/s22082928.

Durante la realización de la presente Tesis Doctoral, he disfrutado de un contrato de Investigador Predoctoral en Formación de la Universidad de Cádiz por un periodo de casi 2 años, desde noviembre de 2018 hasta septiembre de 2020. Posterior he concatenado contratos de Profesor Sustituto Interino.

La presente tesis sigue la estructura requerida en el punto 7 del artículo 23 del Reglamento UCA/CG06/2012.

Resumen

En los últimos años, la potencia fotovoltaica instalada global ha crecido notablemente, llegando a superar el 20% de la demanda energética en varios países. Esto se debe en parte a la reducción de costes de esta tecnología y la política de promover el uso de energías renovables.

La producción de la energía fotovoltaica depende directamente de los niveles de radiación solar incidente sobre los paneles, que se trata de un recurso externo y variable. La irradiancia solar fluctúa principalmente por dos factores, pero la mayor variabilidad está asociada a la presencia de nubes, y estas variaciones tienen una duración que va desde unos pocos segundos hasta varios minutos.

Debido al funcionamiento del mercado eléctrico y a la nula inercia en la producción energética de estos sistemas, los productores fotovoltaicos necesitan de predicciones precisas en diferentes horizontes temporales con el fin de maximizar la energía ofertada en el mercado, incrementando de este modo la integración de la misma. Por otra parte, también necesitan datos en tiempo real para una gestión más óptima del sistema fotovoltaico.

Las predicciones a corto plazo se emplean para el sistema de control y balance de la producción energética, y a medio plazo para la programación y venta de energía en el mercado eléctrico, sin embargo, los sistemas actuales de predicción son escasos y caros para ser contemplados en sistemas de media y pequeña escala.

Numerosos estudios han intentado cubrir la necesidad de predicción a corto plazo estimando espacio-temporalmente el campo de irradiancia con cámaras de cielo completo e imágenes de satélite, sin embargo, estos métodos están limitados por la problemática de la conversión de imagen a irradiancia.

Investigadores influyentes en este área creen que las redes de sensores de irradiancia pueden jugar un papel fundamental en este contexto, ofreciendo en tiempo real varias medidas espaciales y con la alta resolución temporal necesaria. La información espacio-temporal capturada por la red permitiría estimar el campo de irradiancia y analizar su evolución, capturando incluso los eventos más rápidos.

Las tecnologías inalámbricas han evolucionado en el marco de las ciudades

inteligentes y el internet de las cosas, apareciendo tecnologías que se adecuan a diferentes escenarios. El interés mostrado en estos sistemas ha producido un abaratamiento de los módulos de comunicaciones inalámbricas, gracias a la economía de escala. Las redes de sensores podrían beneficiarse de estas tecnologías inalámbricas, ofreciendo a su vez un ahorro en costes del despliegue respecto a su equivalente cableado y una mayor flexibilidad para integrar nuevos nodos en la red.

Por ello, esta tesis se pretende estudiar el potencial de estas redes inalámbricas como fuente de información crítica para la gestión a corto plazo de sistemas fotovoltaicos, y la explotación de los datos de la misma, implementando y desarrollando algoritmos con estos datos con fines de predicción de la producción y para la operación óptima de estos sistemas.

Abstract

In recent years, global installed photovoltaic power has grown significantly, exceeding 20% of energy demand in several countries. This is partly due to the cost reduction of this technology and the policy of promoting the use of renewable energies.

Photovoltaic energy production depends directly on the levels of solar radiation incident on the panels, which is an external and variable resource. Solar irradiance fluctuates mainly due to two factors, but the greatest variability is associated with the presence of clouds, and these variations range in duration from a few seconds to several minutes.

Due to the functioning of the electricity market and the lack of inertia in the energy production of these systems, PV producers need accurate forecasts at different time horizons in order to maximize the energy offered in the market, thus increasing the integration of the same. On the other hand, they also need real-time data for more optimal PV system management.

Short-term forecasts are used for the energy production control and balancing system, and medium-term forecasts are used for scheduling and selling energy in the electricity market, however, current forecasting systems are scarce and expensive to be contemplated in medium and small-scale systems.

Numerous studies have attempted to address the need for short-term forecasting by estimating the spatio-temporal irradiance field with full-sky cameras and satellite imagery, however, these methods are limited by the problems of image-to-irradiance conversion.

Influential researchers in this area believe that irradiance sensor networks can play a key role in this context, providing various spatial measurements in real time and with the necessary high temporal resolution. The spatio-temporal information captured by the network would allow estimating the irradiance field and analyzing its evolution, capturing even the fastest events.

Wireless technologies have evolved within the framework of smart cities and the internet of things, with the emergence of technologies that are suitable for different scenarios. The interest shown in these systems has led to a reduction in the cost of wireless communications modules, thanks to economies of scale. Sensor networks could benefit from these wireless technologies, offering savings

in deployment costs compared to their wired equivalent and greater flexibility to integrate new nodes in the network.

Thus, this thesis aims to study the potential of these wireless networks as a source of critical information for the short-term management of photovoltaic systems, and the exploitation of the data from it, implementing and developing algorithms with this data for production prediction purposes and for the optimal operation of these systems.

Índice

1. Introducción	1
1.1 Marco de desarrollo	1
1.2 Situación de la energía solar	1
1.3 Instrumentos para la monitorización de la irradiancia solar	3
1.4 Importancia de la predicción solar	6
1.5 Necesidades para la mejora de la integración y gestión de parques fotovoltaicos	8
2. Hipótesis y objetivos	10
2.1 Hipótesis	10
2.2 Objetivos	10
3. Justificación de la unidad temática de la tesis	12
4. Análisis crítico de los antecedentes	15
4.1 Introducción	15
4.2 Consideraciones fundamentales	16
4.2.1 Componentes de la irradiancia solar	16
4.2.2 Masa de aire atmosférica y factor de turbidez de Linke	17
4.2.3 Modelos de cielo claro (<i>Clear Sky Models</i>)	17
4.2.4 Índices cielo claro e índice de claridad	17
4.2.5 Evaluación del desempeño de las predicciones de irradiancia solar	18
4.3 Técnicas empleadas para la predicción solar	19
4.3.1 Predicciones por persistencia	19

4.3.2	Modelos usando técnicas regresivas	19
4.3.3	Modelos con redes neuronales artificiales	20
4.3.4	Modelos con monitorización remota	21
4.3.5	Predicción numérica meteorológica regional	22
4.3.6	Modelos basados en monitorización in-situ	23
4.4	Redes de sensores de irradiancia más relevantes de la literatura científica	24
4.4.1	Red de sensores de Lanai	25
4.4.2	Red de sensores de la Universidad Tecnológica de Tampere	25
4.4.3	Sistema de predicción solar	26
4.4.4	Red de sensores de Arizona	26
4.4.5	Diseño y operación de una red de irradiancia en la planta solar de Almería	26
4.4.6	Sistema de monitorización en tiempo real para una planta fotovoltaica	26
4.4.7	Método de kriging para estimar la variabilidad en una potencial planta FV	27
4.4.8	Red de monitorización de irradiancia para evaluación de sistemas fotovoltaicos y predicciones locales	28
4.4.9	Red de sensores para la predicción a corto plazo de potencia FV	28
4.4.10	Red de Irradiancia solar para análisis y medida	28
4.4.11	Modelo de nubes de advección	29
4.4.12	Estudio de las características del punto de máxima potencia de paneles parcialmente sombreados	29
4.4.13	Red de monitorización de irradiancia en el sur de Alemania	30
4.4.14	Control de plantas fotovoltaicas para la mitigación de la variabilidad de la generación	30
5.	Discusión conjunta de los resultados	31
5.1	Objetivo 1: Revisión del estado del arte de las redes de sensores de monitorización de irradiancia	34
5.2	Objetivo 2: Revisión del estado del arte de los algoritmos de estimación de dirección y velocidad de la nube con redes de sensores	35
5.3	Objetivo 3: Estudio de luxómetros y piranómetros como fuente de información para la monitorización del recurso solar	38

5.4	Objetivo 4: Estudio y caracterización de sistemas de comunicaciones con tecnología inalámbrica y adecuados para sistemas de monitorización de irradiancia enfocados a predicción a corto plazo.	40
5.4.1	Apéndice I	40
5.4.2	Apéndice III	41
5.5	Objetivo 5: Desarrollo y validación de una red de sensores de bajo coste para la monitorización de irradiancia.	45
5.5.1	Apéndice I	45
5.5.2	Apéndice III	47
5.5.3	Protocolo de la capa de aplicación	48
5.6	Objetivo 6: Análisis y desarrollo de un sistema de adquisición para los datos de la red de sensores.	52
5.7	Objetivo 7: Desarrollo de algoritmo para la estimación de la dirección y velocidad de la nube.	53
5.7.1	Consideraciones preliminares	53
5.7.2	Modelos de referencia	55
5.7.3	Propuesta de un nuevo método	56
5.7.4	El método del error medio absoluto acumulado	59
5.7.5	Resultados	61
5.7.6	Generalización para redes no malladas	62
6.	Conclusiones	65
6.1	Resumen de las conclusiones más relevantes	65
7.	Perspectivas futuras	69
8.	Bibliografía	70
9.	Apéndices	76
	Apéndice I	77
	Apéndice II	90
	Apéndice III	109

10. Documentación del doctorado **128**

10.1 Informe con el factor de impacto y cuartil de Journal Citation Reports (SCI o SSCI)	151
--	-----

Índice de tablas

3.1	Descripción de los apéndices	12
3.2	Correspondencia de los objetivos con los apéndices	13
4.1	Técnica, fuente de datos, horizontes de predicción y resolución espacial de los modelos de predicción más usados	16
4.2	Estadísticos empleados para caracterizar los modelos de predicción de irradiancia solar	18
4.3	Redes de sensores de irradiancia	24
5.1	Estadísticos de la calibración de los nodos desarrollados en el artículo del Apéndice I	38
5.2	Comparativa de tecnologías IoT para una red de sensores inalámbrica	47
5.3	Comparativa de los principales protocolos de la capa de aplicación para IoT	48
5.4	Especificaciones del piranómetro SP-214	50

Índice de Figuras

1.1	Evolución del precio de los módulos fotovoltaicos	2
1.2	Evolución global acumulativa de instalaciones fotovoltaicas	3
1.3	Instrumentos para la medida de la irradiancia solar	4
1.4	Instrumentos y configuraciones para la obtención del GHI, GTI y DNI	4
1.5	Instrumentos para la medida del DHI.	5
1.6	Piranómetro de fotodiodo.	6
1.7	Espectro de la radiación solar y respuesta espectral de un piranómetro de termopila y otro de fotodiodo.	6
1.8	Presencia de nubes por efecto del estrecho de Gibraltar	8
4.1	Capas genéricas de una red neuronal artificial.	21
4.2	Red de sensores empleada en el estudio de Monger	27
4.3	Distribución de la red de sensores empleadas en el estudio de modelo de nubes de advección.	29
4.4	Distribución de los 17 sensores de irradiancia alrededor del aeropuerto en Oahu, Hawaii.	30
5.1	Estructura de piranómetros usadas para el método MCP	36
5.2	Representación de los tres sensores para el desarrollo del algoritmo LCE, (a) para la particularización de ángulo recto, (b) generalización para cualquier ángulo	36
5.3	Disposición de sensores empleada para el método del SCM	37
5.4	Disposición de sensores empleadas por el método de la matriz del gradiente	37

5.5	Análisis durante un evento de sobre-irradiancia: a) Trayectoria en un diagrama de dispersión, b) Comparación en el dominio del tiempo, c) Comparación de la estimación y la medida de irradiancia.	39
5.6	a) Distribución agregada de errores. b) Distribución de errores de cada nodo.	39
5.7	Rendimiento de la red bajo diferentes configuraciones a) Ratio de paquetes recibidos-enviados b) Desviación estándar del tiempo muestreo respecto al periodo de muestreo solicitado, c) Retraso medio del paquete sobre el muestreo solicitado.	41
5.8	Servidor NTP local GMR5000 de <i>Masterclock Inc.</i>	42
5.9	Histogramas agregados de envío para cada periodo de muestreo probado. Cada periodo de muestreo (<i>Sampling Period, SP</i>) es indicado en el título de los histogramas.	43
5.10	Histogramas de recepción para cada periodo de muestreo (SP) probado, que es indicado en el título de los histogramas.	44
5.11	Ratio de pérdidas de paquetes frente al periodo de muestreo de la prueba.	45
5.12	Esquemático y aspecto final del nodo ZigBee desarrollado en el artículo del Apéndice I	46
5.14	Secuencia de 60 segundos del campo de irradiancia.	46
5.13	Irradiancia estimada por los 16 nodos: a) ventana de 10 minutos de duración, b) detalle de 15 segundos.	47
5.15	Comparativa del ADC a diferentes tasas de muestreo.	49
5.16	Diagrama electrónico del nodo de la red de sensores inalámbrica.	50
5.17	Electrónica y aspecto del prototipo	51
5.18	Red de sensores WiFi desplegada en la azotea del edificio. Los círculos rojos indican la ubicación de los piranómetros, el círculo azul ubica la posición de las fuentes de alimentación y el router.	51
5.19	60 s de 16 series temporales de irradiancia capturada por la red de sensores el 10 de Febrero de 2022.	52
5.20	Evolución del campo de irradiancia a 500 ms de la serie temporal mostrada en la Figura 5.19. donde cada fila representa una duración de 10 segundos, y la diferencia entre dos columnas consecutivas de cada fila es de 500 ms.	53
5.21	Topología de red empleada para la comparativa de los sistemas de adquisición. Los puntos representan el resto de nodos de la red.	54

5.22 Flujo de datos implementado en Node-RED para el sistema de adquisición de MariaDB.	54
5.23 Topología de la red final.	55
5.24 a) Esquema de una red de sensores de 4 x 4 con una nube desplazándose en la dirección y velocidad indicada por el vector v. b) Campo de irradiancia en instante inicial t . c) Campo de irradiancia en el instante $t+1s$	55
5.25 Generación de instantáneas de la red de monitorización mediante el modelo de nube fractal. Las gráficas superiores de la derecha muestran la evolución del área monitorizada dado el CMV representado en el centro de las gráficas. La posición de los sensores está indicado mediante una 'x'. Las gráficas inferiores de la derecha muestran las instantáneas que se obtendría por la red de sensores.	56
5.26 Las dos primeras columnas representan instantáneas de irradiancia en el tiempo t y $t+1$ en cuatro situaciones teóricas con un CMV común ($CMV=(2D,1D)$), representado por la flecha roja. El resto de columnas muestra los diagramas de desplazamiento obtenidos con los coeficientes de similitud mostrados en la parte superior de la columna. La mejor coincidencia de desplazamiento está asociado con el mayor valor de r , \bar{r} y \bar{r}' , y con el valor más bajo del MAE (<i>Mean Absolute Error</i>)	58
5.27 Instantáneas de irradiancia en el tiempo t y $t+1$ en tres situaciones teóricas con un $CMV = (2D, 1D)$ común y sus correspondientes diagramas MAE. El gráfico de la derecha representa el diagrama MAE acumulado (<i>Cumulative Mean Absolute Error, CMAE</i>), obtenido por la agregación de los 3 diagramas MAE.	60
5.28 Evolución de los diagramas CMAE durante 300 s. La fila superior está asociado a una red 4 x 4 con $D = 10$ m, $T_s = 1$ y un CMV de entrada de (-5, -17) m/s. El método estima un CMV = (-6.28, -17.11) m/s. La fila inferior está asociado con una red de 10 x 10 con $D = 3.3$ m y $T_s = 1$, con un CMV de entrada de (12, 9) m/s, estimando el método un CMV de (12.18, 8.99) m/s.	61
5.29 Resultados de velocidad para diferentes configuraciones con $T_s = 1s$	62
5.30 Resultados de dirección para diferentes configuraciones con $T_s = 1s$	63
5.31 Resultados de velocidad para diferentes configuraciones considerando $V_{max} = 30m/ss$	64
5.32 Comparación de velocidad para redes de sensores malladas y no malladas.	64

5.33 Comparación de dirección para redes de sensores malladas y no malladas.	64
---	----

CAPÍTULO 1

Introducción

1.1 *Marco de desarrollo*

Esta tesis comenzó a desarrollarse dentro del proyecto TEC2016-77632-C3-3-R denominado “Control y gestión de nanorredes aislables: instrumentos inteligentes para la predicción solar y la monitorización de la energía” a cargo de miembros del grupo de investigación PAIDI-TIC-168 de la Universidad de Cádiz. Este proyecto ha estado coordinado con los proyectos TEC2016-77632-C3-2-R: “Control y gestión de nanorredes aislables: sistema de gestión de electrodomésticos inteligentes”, gestionado por miembros de la Universidad de Córdoba y TEC2016-77632-C3-3-R: “Control y gestión de nanorredes aislables: estrategias de control para nanorredes aislables” a cargo de miembros de la Universidad de Extremadura. Esta tesis concluyó dentro del proyecto PID2019-108953RB-C21: “Energy and Meteorological Operational Data for photovoltaic plants (EMOD)”, a cargo de miembros del grupo PAIDI-TIC-168 de la Universidad de Cádiz en coordinación con el proyecto PID2019-108953RA-C22: “Monitoring And Integration of energy data with Seamless Temporal Accuracy for photovoltaic plants (MISTA)”, gestionado por investigadores de la Universidad de Córdoba. Ambos proyectos forman parte de un proyecto principal denominado “Strategies for Aggregated Generation of PhotoVoltaic plants (SAGPV)”.

1.2 *Situación de la energía solar*

El paradigma energético actual junto con la preocupación de una mayor independencia energética y las políticas de neutralidad de CO_2 , como el Acuerdo de París [1] y el Protocolo de Kioto [2] plantean un reto en el desarrollo energético de numerosos los países [3].

Una buena parte de los países confían en las energías renovables como un pilar fundamental para la consecución de los objetivos. Por ello, algunos países incentivaban estas energías con primas económicas. Un ejemplo de ello fue

España, que mediante los Reales Decretos 436/2004 y 661/2007 se establecían las primas sobre la producción de renovables. Estas primas eran importantes para la energía solar fotovoltaica (FV) debido a los bajos rendimientos y altos precios de los paneles FV, Figura 1.1.

Esta situación cambia en torno al año 2010, cuando los paneles comenzaban a presentar un precio más atractivo para nuevos inversores y a consecuencia de ello, la potencia solar fotovoltaica instalada tuvo un crecimiento exponencial en numerosos países, Figura 1.2. Hoy en día, la integración de las energías renovables llega a superar el 20 % de la demanda energética en algunos países desarrollados [4]. La Agencia de Energía Internacional (*International Energy Agency, IEA*) estima que dicha tendencia continúe al menos durante los próximos años [5] [6].

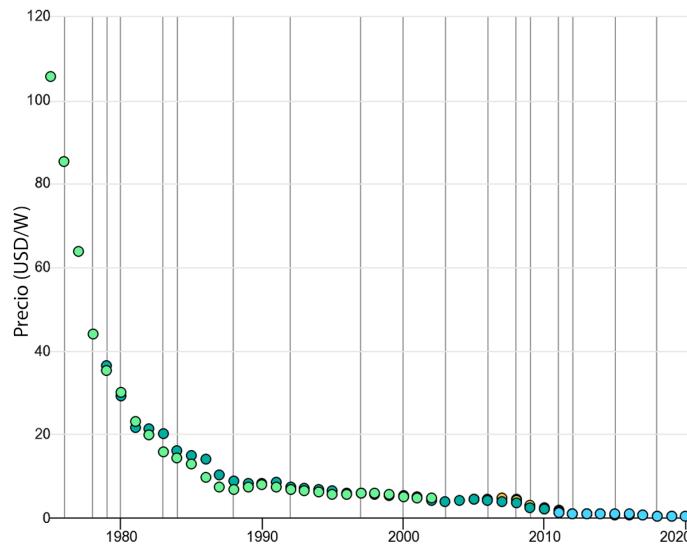


Figura 1.1: Evolución del precio de los módulos fotovoltaicos. Dólar estadounidense por Vatio. Las líneas verticales marcan el momento en el que se duplica la capacidad instalada acumulada. Fuente: [7].

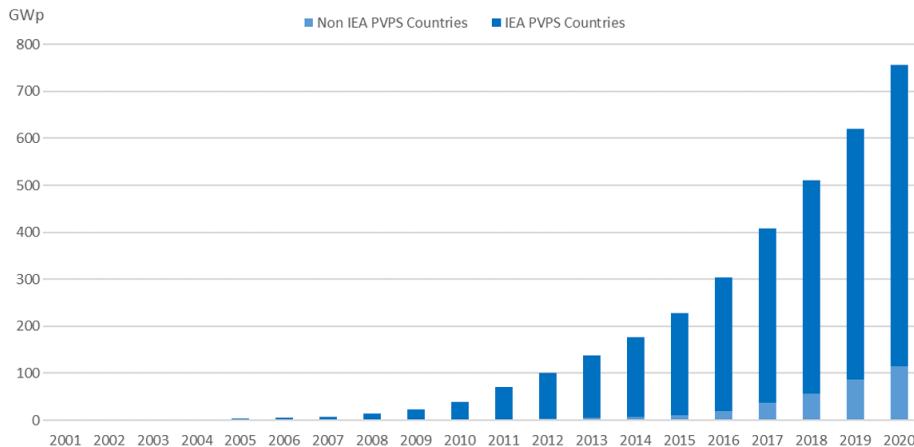


Figura 1.2: Evolución global acumulativa de instalaciones fotovoltaicas. Fuente: [5]

1.3 Instrumentos para la monitorización de la irradiancia solar

La producción fotovoltaica depende de la radiación incidente en los paneles FV. Por ello, resulta de interés tener monitorizado el recurso solar. Se pueden medir las componentes de la irradiancia solar en plano horizontal y plano inclinado, siendo las siguientes las más relevantes:

- Irradiancia Global Horizontal (*Global Horizontal Irradiance, GHI*). Es la cantidad de radiación recibida (desde arriba) por una superficie horizontal.
- Irradiancia Global en plano inclinado (*Global Tilted Irradiance, GTI*). Es la cantidad de radiación recibida por una superficie inclinada, como puede ser el plano de los paneles solares.
- Irradiancia Normal Directa (*Direct Normal Irradiance, DNI*). Es la cantidad de radiación solar recibida por una superficie que se mantiene perpendicular a los rayos del sol.
- Irradiancia Horizontal Difusa (*Diffuse Horizontal Irradiation, DHI*). Es la cantidad de radiación recibida por una superficie que no viene de un camino directo desde el sol.

Las medidas de GHI, DHI y DNI se correlacionan por la Ecuación 1.1

$$GHI = DHI + DNI \cdot \cos(\theta) \quad (1.1)$$

donde θ representa el ángulo cenital solar.



Figura 1.3: Instrumentos para la medida de la irradiancia solar

Todas estas medidas anteriores representan potencia por unidad de área, típicamente en unidades de W/m^2 . En la Figura 1.3 podemos ver los principales instrumentos para la medida de la irradiancia. Todas estas componentes de la radiación solar anteriormente descritas se obtienen con un piranómetro o célula solar de referencia, a excepción del DNI, cuya medida de forma directa requiere el uso de un pirheliómetro.

Para la medida de GHI, se emplea la célula de referencia o piranómetro sobre una superficie horizontal, y en caso de que el objetivo sea la obtención del GTI, se sitúa dicho instrumento en una superficie paralela al plano de interés. En la Figura 1.4a se muestran dos piranómetros con diferentes superficies de apoyo, para obtener las medidas de irradiancia anteriormente indicadas, GHI y GTI.

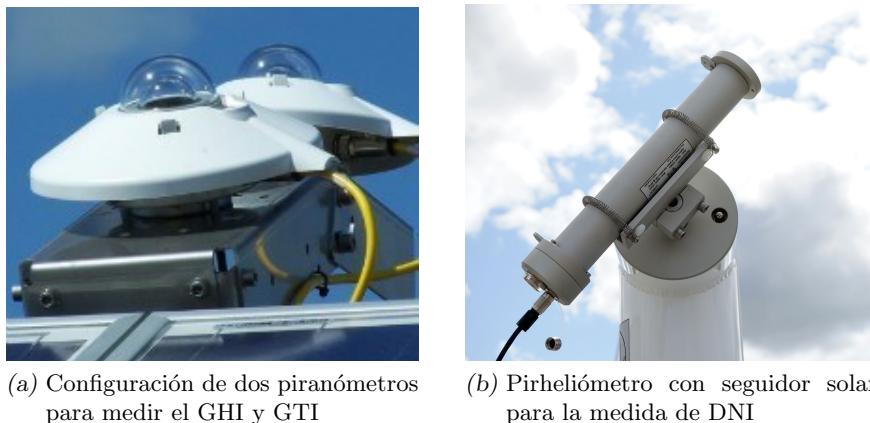


Figura 1.4: Instrumentos y configuraciones para la obtención del GHI, GTI y DNI

El pirheliómetro se emplea para medir directamente el DNI, como se comentó anteriormente. Este instrumento es básicamente un tubo con una pequeña ventana y el sistema de un piranómetro en el interior del otro extremo del tubo, de forma que la radiación difusa es excluida de la medida. Este instrumento

requiere además del empleo de un sistema con seguidor solar como el mostrado en la Figura 1.4b.

La medida de la radiación horizontal difusa (DHI) también se obtiene con el piranómetro, pero con una sombra que bloquea los rayos solares que provienen directamente del sol. Existen dos formas principales de bloquear la radiación directa; una es mediante un anillo opaco que se coloca estratégicamente para bloquear la radiación directa desde la salida hasta la puesta del sol y el otro, es un pequeño disco opaco que se mueve con un seguidor solar. En la Figura 1.5 se muestran ambos sistemas.

El sistema basado en anillo de sombra es más económico que el sistema con seguidor solar, pero presenta dos inconvenientes: existe una pequeña desviación de la medida, puesto también bloquea parcialmente la radiación difusa y requiere un ajuste periódico del anillo (máximo unos pocos días) debido a las variaciones de la trayectoria solar durante el año.



(a) Anillo de sombra para la obtención del DHI con un piranómetro
 (b) Seguidor solar con pirhelíometro y piranómetro con radiación solar directa bloqueada para la medida del DNI y DHI

Figura 1.5: Instrumentos para la medida del DHI.

Los piranómetros se pueden clasificar por su principio de funcionamiento, siendo los más comunes el piranómetro de termopila (Figura 1.3b) y el piranómetro de fotodiodo (Figura 1.6). Cada uno de ellos tiene sus diferentes características que lo hacen más apropiados según el uso. Por ejemplo, el piranómetro de fotodiodo tiene un tiempo de respuesta más rápido que el de termopila, sin embargo, este último suele tener una respuestapectral más amplia. Para comprender mejor esta diferencia, en la Figura 1.7 se muestra la

respuesta espectral de ambos tipos de piranómetros junto con el espectro típico de la radiación solar.



Figura 1.6: Piranómetro de fotodiodo.

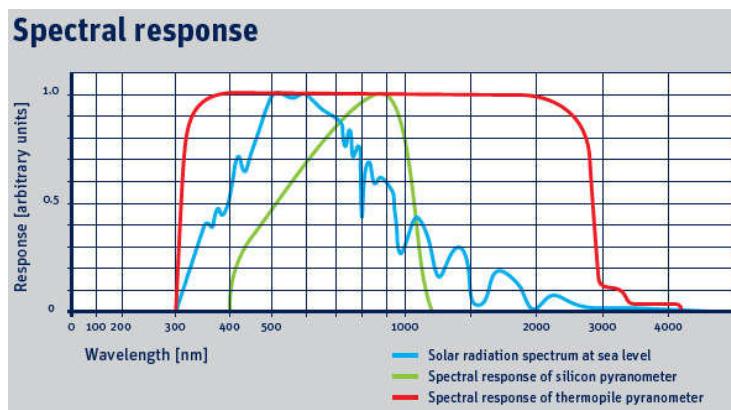


Figura 1.7: Espectro de la radiación solar y respuesta espectral de un piranómetro de termopila y otro de fotodiodo. En rojo y en verde, las respuestas espectrales de un piranómetro de termopila y de fotodiodo, respectivamente. En azul, el espectro de radiación solar típica al nivel del mar. Fuente [8].

1.4 Importancia de la predicción solar

La información solar, especialmente las predicciones en los diversos horizontes temporales, juega un papel fundamental en el aprovechamiento de esta energía. La producción fotovoltaica depende de la radiación solar que llega a la superficie de los paneles FV, que se trata de un recurso externo y variable.

La variación de la radiación solar recibida en la superficie terrestre depende principalmente de dos factores. Uno de ellos es la posición del sol, que es una fluctuación determinista y que presenta poca variación en horizontes temporales

cortos. El índice de radiación debido a la posición del sol se suele calcular mediante el uso de los modelos de cielo claro y de claridad, que son descritos en la sección 4.2.4. Resulta relevante destacar que estos modelos contemplan los efectos de la presencia de otros agentes como polvo en suspensión y vapor de agua los cuales afectan a los niveles de radiación solar terrestre, que son condiciones atmosféricas que no suele presentar grandes variaciones a corto plazo.

El otro factor y el que tiene mayor impacto sobre el nivel de radiación incidente es la presencia de nubes entre el sol y el panel solar. Se trata de un proceso estocástico, difícil de modelar y caracterizado por tener una duración que va desde algunos segundos a varios minutos.

Las fluctuaciones de irradiancia debido a las nubes es la principal causa de incertidumbre en los modelos de predicción. Debido a esto, la precisión de predicción de la irradiancia solar depende casi exclusivamente de la habilidad para predecir esta componente estocástica [9] [10] [11].

Los productores de energía fotovoltaica suelen tener en cuenta la incertidumbre de los modelos de predicción para acudir al mercado eléctrico. Por lo general, toman una posición conservadora teniendo en cuenta dicha incertidumbre. Esto significa que el productor acude al mercado eléctrico vendiendo menos energía de la que en un principio puede generar, pero por otra parte, también disminuye el riesgo a recibir una sanción económica por incumplimiento del contrato de producción. Por ello, resulta de interés la posibilidad de acceder a predicciones a corto plazo precisas, con horizonte temporal de un día y resolución horaria. De este modo, se puede maximizar la energía ofertada en el mercado eléctrico. Antonanzas en [12] cuantifica económicamente el impacto de la precisión de las predicciones en el mercado eléctrico.

Por otra parte, las predicciones de cambios de irradiancia en el corto plazo también tienen interés para el cumplimiento de las regulaciones de algunos países. El trabajo [13] recoge las regulaciones más importantes en algunos sistemas eléctricos, como el cumplimiento de la tasa máximas de variación de potencia o el rango del factor de potencia en el punto de inyección.

Las predicciones a largo plazo junto con el análisis de datos históricos de irradiancia también tienen valor para localizar zonas geográficas donde se maximice la irradiancia anual recibida. Dos zonas cercanas, como pueden ser Bolonia (Tarifa) y Algeciras, pueden presentar diferencias en los índices de radiación anual debido a la presencia de microclimas y efectos locales. Refiriéndonos a estas dos zonas como ejemplo ilustrativo, bajo ciertas condiciones, el paso de las masas de aire por el estrecho de Gibraltar favorece la aparición de nubes.

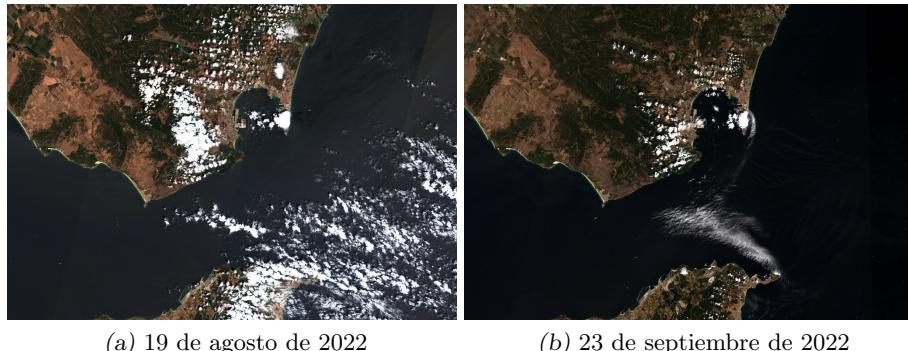


Figura 1.8: Presencia de nubes por efecto del estrecho de Gibraltar. La imagen (a) corresponde al día 19 de agosto de 2022 y (b) al 23 de septiembre de 2022. Imágenes obtenidas de Sentinel EO Browser[14]

1.5 Necesidades para la mejora de la integración y gestión de parques fotovoltaicos

La integración de energía fotovoltaica en la red eléctrica está limitada debido a la nula inercia en la producción de los paneles FV y la dificultad de predecir a corto plazo la alta variabilidad inducida por las nubes.

Es relevante destacar en este punto que una medida puntual no refleja la dimensión espacio temporal del recurso solar y por tanto, no es completamente descriptiva de la producción de una planta. La dimensión espacio temporal afecta en pequeña escala a mermas en la producción por pérdidas del punto de máxima potencia (*Maximum Power Point, MPP*), y a grandes escalas las fluctuaciones rápidas quedan suavizadas, de modo que la generación no presenta estas variaciones rápidas. Las variaciones repentinas en la generación de los sistemas FV pueden provocar fluctuaciones de tensión que requieran de un mayor número de operaciones de regulación en los alimentadores de red.

Es la variabilidad de la producción la que causa los mayores problemas para la integración, y por ello, la comunidad científica ha intentado mitigar dicho efecto empleando diversas técnicas, entre las que se pueden destacar la dispersión geográfica [15], el almacenamiento energético (baterías principalmente) [16] [17], limitación de potencia progresiva [18] y pilas de combustible/grupos electrógenos [19].

El uso de la técnica de la dispersión geográfica para reducir la variabilidad de alta frecuencia requiere que los paneles fotovoltaicos estén distribuidos por una superficie más o menos extensa sin grandes agrupamientos, lo que implica unas necesidades mayores de superficie que un parque fotovoltaico convencional (concentrado). Hoff en [11] modela la variabilidad máxima en función de la cantidad de sitios no correlacionados y la potencia de la planta.

El resto de técnicas pueden ofrecer mayores beneficios en caso de disponer de predicciones precisas de los minutos siguientes. Para técnicas con baterías, la cantidad de almacenamiento de energía necesario puede ser optimizado (minimizado) [20]. Las técnicas que aplican limitación de potencia progresiva se podrían aplicar no solo a las subidas de potencia generada, sino que también a las bajadas. Las técnicas que emplean generadores de apoyo como las pilas de combustible y grupos electrógenos, podrían entrar en funcionamiento para las rampas rápida, ya que actualmente solo pueden mitigar las rampas lentas debido a los tiempos de respuestas de estos generadores [21].

Por todo ello, las predicciones a corto plazo resultan ser una fuente de información muy valiosa para los sistemas de gestión de la planta y balance de la producción energética.

De toda esta situación se infiere la necesidad de mejorar las predicciones de la irradiancia solar en múltiples horizontes temporales para facilitar una mayor penetración de la energía fotovoltaica en el mercado eléctrico [9] [22].

CAPÍTULO 2

Hipótesis y objetivos

La mejora de las predicciones de corto plazo de la irradiancia mejorarían la eficiencia de la gestión de los parques FV y la integración de su energía en el sistema eléctrico.

En esta tesis se pretende estudiar el potencial de las redes de sensores de irradiancia como fuente de información crítica para la gestión a corto plazo de sistemas fotovoltaicos, analizando distintas soluciones acordes a lo que ofrece la tecnología actual, y desarrollando algoritmos para explotación de estos datos con fines de predicción de la producción para la operación óptima de estos sistemas.

2.1 *Hipótesis*

1. Las redes de sensores pueden constituir una fuente de datos operacionales fundamental para la gestión óptima de los sistemas fotovoltaicos, facilitando su integración en la red eléctrica.
2. Las tecnologías de comunicación inalámbricas actuales pueden alcanzar las especificaciones más exigentes para la monitorización del recurso solar a un coste razonable.
3. Los datos obtenidos de una red de sensores de piranómetros ofrecen una base sólida sobre la que aplicar algoritmos capaces de estimar los desplazamientos de las sombras de nubes, que en última instancia son la fuente primaria de variabilidad de esta fuente de energía.

2.2 *Objetivos*

La consecución del objetivo principal, y la confirmación de las hipótesis expuestas, se plantea a partir de una serie de objetivos parciales que se detallan a continuación:

1. **Revisión del estado del arte de las redes de sensores de monitorización de irradiancia:** Revisión bibliográfica de las publicaciones que desarrollan o usan redes de sensores con el objetivo descrito, y discusión del diseño óptimo de las mismas para aplicaciones en tiempo real.
2. **Revisión del estado del arte de los algoritmos de estimación de dirección y velocidad de la nube con redes de sensores:** Revisión de los estudios publicados donde se desarrollan y/o evalúan algoritmos para la estimación del movimiento de la nube, empleando como fuente de datos redes de sensores.
3. **Estudio de luxómetros y piranómetros como fuente de información para la monitorización del recurso solar.** Desarrollo de equipos de monitorización con luxómetros y con piranómetros para analizar el comportamiento de cada uno bajo similares condiciones para verificar si los luxómetros podrían ser una alternativa más económica que los piranómetros ofreciendo medidas de calidad similar.
4. **Estudio y caracterización de sistemas de comunicaciones con tecnología inalámbrica y adecuados para sistemas de monitorización de irradiancia enfocados a predicción a corto plazo:** Estudio y evaluación de tecnologías inalámbricas que puedan ser empleadas para diseñar una red de sensores y que cumpla con las especificaciones requeridas para su fin, principalmente baja latencia, capacidad de alta frecuencia de muestreo y que soporte múltiples dispositivos.
5. **Desarrollo y validación de una red de sensores de bajo coste para la monitorización de irradiancia:** Desarrollo y caracterización del funcionamiento de una red de sensores inalámbrica para la monitorización espacial de irradiancia, teniendo en cuenta las tecnologías analizadas en el punto anterior.
6. **Análisis y desarrollo de un sistema de adquisición para los datos de la red de sensores:** Estudio de las técnicas y sistemas más comunes para la adquisición de series de irradiancia. Desarrollo y evaluación del rendimiento de los sistemas de adquisición.
7. **Desarrollo de algoritmo para la estimación de la dirección y velocidad de la nube:** Obtención de datos de irradiancia con redes de sensores para su posterior análisis, y en base a esta información, el desarrollo de un algoritmo que permita estimar el vector de movimiento de nube con la información obtenida de una red de sensores en tiempo real.

CAPÍTULO 3

Justificación de la unidad temática de la tesis

Esta tesis se presenta como un compendio de publicaciones. Los artículos considerados se encuentran en los apéndices I, II y III. La tabla 3.1 contiene una descripción de cada apéndice.

Tabla 3.1: Descripción de los apéndices

Apéndice	Título	Descripción
Apéndice I (artículo)	An on-line low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV systems	El objetivo principal de este estudio es el desarrollo de una red de monitorización de bajo coste que sirva para la aplicación de algoritmos de estimación de dirección y velocidad de la sombra de la nube, así como una fuente de información para sistemas de predicción. El bajo coste se consigue en parte con el uso de sensores de iluminación en lugar de piranómetros, y microcontroladores con capacidades de comunicaciones inalámbricas para reducir los costes de cableado y despliegue de la red.

Apéndice II (artículo)	Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method	En este trabajo se realiza un análisis general de la estimación del movimiento de la nube desde los datos obtenidos de una red de monitorización de irradiancia, así como la propuesta y comparación de un nuevo método con las técnicas actuales usando fuentes de datos similares. La comparación se realiza desplazando una nube sintética generada con un modelo fractal sobre el área monitorizada, conociendo de este modo el CMV real.
Apéndice III (artículo)	Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring	En este artículo se detalla el diseño una red de monitorización de alto rendimiento que mejora y soluciona ciertos aspectos de la anterior red diseñada y se propone una infraestructura de software para la adquisición y almacenamiento de datos. Se analizan los aspectos más relevantes del conjunto: comparación de la precisión de los ADCs, rendimiento de las bases de datos bajo estudio, sincronización de los dispositivos, y estabilidad en el envío y recepción de los datos.

Los objetivos descritos en la subsección 2.2 han sido cubiertos en esta tesis doctoral mediante las publicaciones indicadas en los apéndices. La Tabla 3.2 muestra la correspondencia entre los objetivos y los apéndices.

Tabla 3.2: Correspondencia de los objetivos con los apéndices

Objetivo	Correspondencia
Revisión del estado del arte de las redes de monitorización de irradiancia	Apéndice I Apéndice II Apéndice III
Revisión del estado del arte de los algoritmos de estimación de dirección y velocidad de la nube con redes de sensores	Apéndice II

Estudio de luxómetros y piranómetros como fuente de información para la monitorización del recurso solar	Apéndice I
Estudio y caracterización de sistemas de comunicaciones con tecnología inalámbrica y adecuados para sistemas de monitorización de irradiancia enfocados a predicción a corto plazo	Apéndice I Apéndice III
Desarrollo y validación de una red de sensores de bajo coste para la monitorización de irradiancia	Apéndice I Apéndice III
Análisis y desarrollo de un sistema de adquisición para los datos de la red de sensores	Apéndice I Apéndice III
Desarrollo de algoritmo para la estimación de la dirección y velocidad de la nube	Apéndice II

Como se puede observar, los objetivos propuestos quedan cubiertos por las publicaciones incluidas en esta tesis doctoral.

CAPÍTULO 4

Análisis crítico de los antecedentes

4.1 Introducción

Debido a que las nubes son la principal fuente de variabilidad de la producción fotovoltaica, la comunidad científica ha intentado realizar predicciones de las mismas mediante el uso de diferentes fuentes de información.

Algunos autores han abordado este problema mediante el uso de modelos meteorológicos numéricos, [23] [24] [25], y monitorización remota desde satélites [26] [27] [28] y [29]. Hasta hoy en día, estas fuentes de datos han demostrado su utilidad en el medio plazo, pero no son eficaces para abordar la predicción a corto plazo debido a que su resolución espacial y temporal, de 1 a 8 km/pixel, y con frecuencia de actualización máxima entre 5 y 15 minutos [30], resulta inadecuada para sistemas fotovoltaicos.

Otros autores han usado cámaras de cielo completo (*All Sky Cameras*) [31] [32], sin embargo, debido a la naturaleza de la misma, la predicción de irradiancia solar a partir de imágenes están muy limitadas por los errores de conversión de imagen a irradiancia [33]. A pesar de numerosos esfuerzos de la comunidad científica, no se ha encontrado una solución que minimice de forma eficaz estos errores.

Debido a los inconvenientes presentados por las fuentes de información comentadas, en los últimos años se ha puesto especial interés en las redes de sensores, ya que permiten conocer la realidad a nivel de suelo (*ground truth*). La disminución de los costes asociados al desarrollo y despliegue de una red de sensores de irradiancia [33] hace potencialmente atractiva esta fuente para plantas fotovoltaicas medianas (cientos kWp) y grandes, aunque su coste no estaría justificado para pequeños productores fotovoltaicos (casas y naves industriales) [34].

La tabla 4.1 es un resumen los principales técnicas de predicción, las fuentes de datos y las características típicas de cada una. En las siguientes secciones se desarrolla de forma breve cada una de ellas.

Tabla 4.1: Técnica, fuente de datos, horizontes de predicción y resolución espacial de los modelos de predicción más usados

Técnica	Fuente de datos	Horizonte temporal	Resolución espacial
Persistencia	Series temporales de irradiancia	1s – 10min	puntual
Regresivos	Series temporales de irradiancia	1s – 10min	puntual
Redes neuronales	Series temporales de irradiancia	1s – 10min	puntual
Monitorización remota	Satélites	1 – 6h	1 – 8 km
Predicciones numéricas meteorológicas	Satélites Datos meteo.	3h – 10 días	10 – 50km
Imagen a irradiancia	Satélites Cámaras de cielo	5 – 30min	20-100m
Basados en redes de sensores	Series temporales de irradiancia	1s – 30min	20m-1km

4.2 Consideraciones fundamentales

Esta sección describe algunos de los aspectos fundamentales que se suelen tener en cuenta en las predicciones de irradiancia.

4.2.1 Componentes de la irradiancia solar

La irradiancia incidente que llega a la parte más externa de la atmósfera es llamada irradiancia solar extraterrestre y tiene un valor promedio de 1360 W/m^2 . Esta irradiancia, en su camino a la superficie de la tierra, se ve atenuada debido a reflexiones, absorciones y re-emisiones debido a interacciones con los constituyentes de la atmósfera [35]. Esto resulta en la división de la irradiancia que llega a la superficie de la tierra en dos componentes: Irradiancia Normal Directa (*Direct Normal Irradiance, DNI*) e Irradiancia Horizontal Difusa (*Diffuse Horizontal Irradiance, DHI*). La suma geométrica de ambas recibe el nombre de Irradiancia Global Horizontal (*Global Horizontal Irradiance, GHI*) y se puede escribir del siguiente modo:

$$GHI = DHI + DNI \cdot \cos(\theta) \quad (4.1)$$

donde θ es el ángulo cenital solar.

4.2.2 Masa de aire atmosférica y factor de turbidez de Linke

La masa de aire atmosférica (*Atmospheric airmass, AM*) y el factor de turbidez de Linke son dos coeficientes que se emplean a menudo.

La masa de aire se define como la longitud del camino óptico directo a través de la atmósfera terrestre, expresado como una relación relativa a la longitud del camino más corto (normal al suelo, cuando el sol se encuentra en su punto más alto ($\theta = 0$)), en este momento se considera que la masa de aire tiene un valor unitario, $AM = 1$. Si el ángulo cenital solar se incrementa, también lo hace la masa de aire (AM).

El factor de turbidez de Linke (*Linke Turbidity factor, LT*) se define como el número de atmósferas en condiciones limpias y secas que produciría los mismos efectos de atenuación y dispersión en un determinado punto. A modo de referencia, $LT = 1$ describe una atmósfera de Rayleigh solo con efectos de dispersión molecular y $LT > 1$ representa además los efectos del vapor de agua, gases, aerosoles y partículas en suspensión. Es posible obtener el factor de turbidez de Linke a partir de medidas directas de Irradiancia Normal Directa (DNI)

4.2.3 Modelos de cielo claro (*Clear Sky Models*)

Muchos modelos de predicción requieren del conocimiento de las condiciones de cielo claro (*Clear Sky Conditions*), que son condiciones que se caracterizan por la ausencia de nubes. Los modelos de cielo claro son usados para las predicciones por persistencia (ver sección 4.3.1) y para la evaluación de la habilidad de predicción de otros modelos. Las predicciones basadas en datos de satélite también usan modelos de cielo claro para derivar las componentes de la irradiancia solar a nivel de suelo, y es usado frecuentemente en ubicaciones donde no existen otras medidas [35].

4.2.4 Índices cielo claro e índice de claridad

Los índices de claridad (*Clearness, K_t*) y cielo claro (*Clear Sky, k_t*) son dos índices similares y frecuentemente usados en la predicción de la irradiancia solar. Ambos difieren únicamente en el factor usado en la definición de su normalización.

El índice de cielo claro se define como el ratio entre la irradiancia medida y la irradiancia de cielo claro modelada a nivel de suelo, ecuación 4.2

$$k_t = \frac{I_t}{I_t^{clr}} \quad (4.2)$$

El índice de claridad se define como la relación de la radiación a nivel de suelo con respecto a la irradiancia extraterrestre, ecuación 4.3

$$K_t = \frac{I_t}{I_t^{EX}} \quad (4.3)$$

La irradiancia extraterrestre es fácil de modelar debido a la ausencia de fluctuaciones por interacciones con la atmósfera, y se define como en ecuación 4.4

$$I_t^{EX} = I_0 \cos(\theta_t) \quad (4.4)$$

donde $I_0 = 1360W/m^2$ y θ_t es el ángulo cenital solar en el tiempo t .

4.2.5 Evaluación del desempeño de las predicciones de irradiancia solar

Las técnicas de predicción de irradiancia solar se han desarrollado y probado en diversos puntos del planeta y la comparación entre distintos métodos puede ser tedioso y confuso debido a diferente localización geográfica, mes del año, diferencias climáticas, etc. Por ello, los autores suelen usar indicadores estadísticos para caracterizar la calidad de las técnicas de predicción. Los estadísticos más usados para estas caracterizaciones son: el coeficiente de determinación (R^2), error medio absoluto (*Mean Absolute Error, MAE*), error porcentual absoluto medio (*Mean Absolute Percentage Error, MAPE*), el coeficiente de correlación (ρ), raíz del error cuadrático medio (*Root Mean Square Error, RMSE*) y error de sesgo medio (*Mean Bias Error, MBE*). Estos estadísticos quedan recogidos en la tabla 4.2, donde \hat{I} representan las predicciones de los modelos e I los datos de irradiancia.

Tabla 4.2: Estadísticos empleados para caracterizar los modelos de predicción de irradiancia solar

Estadístico	Fórmula
Coeficiente de determinación	$R^2 = 1 - \frac{Var(\hat{I}-I)}{Var(I)}$
Error medio absoluto	$MAE = \frac{1}{N} \sum_{t=1}^N \hat{I}_t - I_t $
Error porcentual absoluto medio	$MAPE = \frac{1}{N} \sum_{t=1}^N \left \frac{\hat{I}_t - I_t}{I_t} \right $
Coeficiente de correlación	$\rho = \frac{(Cov(\hat{I}, I))^2}{Var(\hat{I})Var(I)}$
Error cuadrático medio de la raíz	$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{I}_t - I_t)^2}$
Error de sesgo medio	$MBE = \frac{1}{N} \sum_{t=1}^N N(\hat{I}_t - I_t)$

Usando estos coeficientes es posible comparar unas técnicas de predicción con otras, siendo la comparación más usada la persistencia, teniendo de este modo, una evaluación de la mejoría que se aporta sobre el método más simple (ver sección 4.3.1).

4.3 Técnicas empleadas para la predicción solar

4.3.1 Predicciones por persistencia

Es una de las predicciones más simples de implementar y a menudo usada como base de comparación de otros métodos de predicción, como se ha comentado anteriormente. Estas predicciones asumen que el índice de cielo claro o índice de claridad se mantiene invariante en el siguiente periodo de tiempo. Esta asunción se puede formular matemáticamente del siguiente modo:

$$k_{t+\Delta t} = k_t = \frac{I_t}{I_t^{clr}} \quad (4.5)$$

$$K_{t+\Delta t} = K_t = \frac{I_t}{I_t^{EX}} \quad (4.6)$$

Usando estos índices, la predicción de la irradiancia solar en el siguiente intervalo temporal se puede calcular con las siguientes ecuaciones:

$$I_{t+\Delta t}^{pers_k} = k_t I_{t+\Delta t}^{clr} \quad (4.7)$$

$$I_{t+\Delta t}^{pers_k} = k_t I_{t+\Delta t}^{EX} \quad (4.8)$$

Hay que tener en cuenta que ambas estimaciones necesitan de los índices de cielo claro e índice de claridad, y por tanto, pueden haber varias predicciones de persistencia dependiendo de como I_t^{clr} e I_t^{EX} sean estimados.

4.3.2 Modelos usando técnicas regresivas

Un modelo regresivo es aquel que explica una variable de interés, en este caso la irradiancia, mediante una combinación de una o más variables independientes.

Existen numerosos modelos de predicción de irradiancia fundamentados en esta técnica, con diferentes enfoques de la variable independiente. Entre ellos, se pueden destacar los modelos auto-regresivos (*Auto-regressive models, AR*), de media móvil (*Moving Average, MA*), mixto de media móvil auto-regresivo

(*Mixed Auto-Regressive Moving Average, ARMA*) y mixto de media móvil auto-regresivo con variables exógenas (*Mixed Auto-Regressive Moving Average models with exogenous variables, ARMAX*).

Los modelos de auto-regresivos (AR) plantean que el valor actual de un proceso puede ser expresado como una combinación lineal finita de los valores previos del mismo. Los modelos de media móvil (MA) emplean los errores pasados multiplicados por un coeficiente para estimar los siguientes valores. Por otra parte los modelos mixtos de media móvil auto regresivos (ARMA), como su nombre indica, es una combinación de los dos anteriores.

Hasta ahora, los modelos descritos pueden ser considerados univariados, lo que significa que el modelo usa valores históricos de una única serie temporal. No es así en el caso de los modelos mixtos de media móvil auto-regresivos con variables exógenas (ARMAX), cuyo fundamento es similar al ARMA pero incluye como variable independiente una variable externa al modelo, que suele estar relacionada con variables climáticas o salidas de predicciones numéricas meteorológicas [36] (ver sección 4.3.5).

4.3.3 Modelos con redes neuronales artificiales

Una red neuronal artificial (*Artificial Neural Network, ANN*) es un modelo computacional formado por un grupo de nodos, llamados neuronas, conectados entre sí de modo que presenta cierta semejanza con la topología de la red neuronal del cerebro. Las ANNs pueden encontrar una solución o salida a partir de unos parámetros de entrada, pero para ello es necesario que la red sea sometida a un proceso de entrenamiento o aprendizaje.

Por un lado, presenta la ventaja de que con un buen diseño de entrenamiento la red encontraría una solución cercana a la óptima sin necesidad de conocimientos profundos de la naturaleza de la variable de interés ni de los procesos asociados a la misma. Sin embargo, puede requerir un entrenamiento personalizado cuando las entradas caracterizan una ubicación, están muy vinculadas a la zona geográfica o la calidad de los datos de entrada es diferente, por nombrar algunas razones.

El campo de la inteligencia artificial ha sufrido una evolución importante en los últimos años, por ello, existe una larga lista de tipos de redes neuronales, entre las que podemos destacar: las redes neuronales monocapa (o perceptrón simple), redes neuronales multicapa, redes neuronales convolucionales, redes neuronales recurrentes, etc. Todas estas redes tienen unas partes comunes, la capa de entrada, las capas ocultas y la capa de salida, ver Figura 4.1. En la capa de entrada se encuentran los nodos que contienen la información o vector de entrada a la red. La capa oculta es donde ocurre el procesado y su estructura depende del tipo de red neuronal. Por último, la capa de salida es donde se encuentran los nodos que proporcionan la respuesta final a los estímulos de entrada.

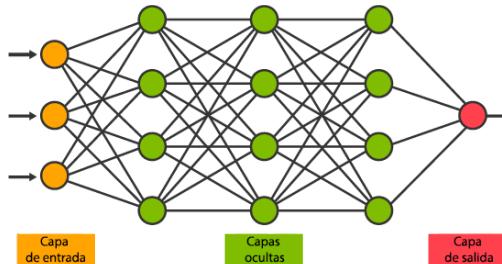


Figura 4.1: Capas genéricas de una red neuronal artificial.

Numerosas redes neuronales diseñadas para la predicción de la irradiancia solar usan como entradas un número finito de datos históricos de la serie de irradiancia [37], datos provenientes de las predicciones numéricas meteorológicas [38], y magnitudes de variables obtenidas con estaciones meteorológicas [39].

4.3.4 Modelos con monitorización remota

Se habla de monitorización remota cuando las medidas del sitio se obtienen mediante teledetección, y que por lo general desde un satélite. Atendiendo a su órbita, los satélites se clasifican en: Satélites de órbita terrestre baja (*Low Earth Orbit, LEO*) y los Satélites geoestacionarios (*GeoStationary Orbit, GSO*).

Las órbitas terrestres bajas se sitúan a una altura aproximada de unos 800 km. Esta órbita baja tiene como implicación un periodo corto de rotación, en torno a los 100 minutos, unas 15 órbitas por día, y por tanto, no puede tomar medidas de un mismo sitio de forma continua.

Las órbitas geoestacionarias son fijas respecto al planeta y se sitúan a una altura aproximada de 36000 km. Este tipo de órbita permite la monitorización continua de un sitio pero con una resolución inferior a las órbitas LEO.

4.3.4.1 Modelos físicos con Satélites

Los modelos físicos con satélites para la predicción solar de la irradiancia están basados en las interacciones entre la radiación solar y los componentes atmosféricos (gases y aerosoles principalmente). Estas interacciones se modelan normalmente por medio de modelos de transferencia radiativos (*Radiative Transfer Models, RTMs*) y dan buenos resultados para horizontes entre 1 y 6 h [35], [40].

4.3.4.2 Modelos basados en técnicas estadísticas con satélites

Estos modelos se basan en regresiones entre la irradiancia solar medida por piranómetros en la superficie de la tierra y las cuentas obtenidas por la instrumentación del satélite en un momento dado. Estos modelos suelen tener en cuenta el ángulo cenital solar, el índice de cobertura de nube, la transmisividad atmosférica y el brillo instantáneo [35].

Existe un inconveniente principal al trabajar con este método. Debido a la baja resolución espacial del satélite, es difícil localizar y comparar los datos obtenidos por los piranómetros.

4.3.4.3 Modelos basados en imágenes de satélite

Algunos autores han abordado la predicción empleando imágenes de cielo desde satélites. La mayoría de ellos precisan de la estimación del vector de movimiento de nube (*Cloud Motion Vector, CMV*) para intentar predecir la posición de las nubes en las siguientes horas o minutos. Para ello se emplean diversas técnicas como correlación cruzada (*cross correlation*), Lucas-Kanade, Harris Corner, etc. [41].

Estos modelos además precisan obtener de algún modo la distribución de irradiancia. Hay autores que intentan correlacionar la intensidad del pixel con la irradiancia en el suelo, otros intentan obtener los índices de cielo claro e índice de claridad, otros intentan clasificar los tipos de nubes, etc. Es común encontrar estos métodos empleados conjuntamente con otras técnicas como inteligencia artificial, bien sea para la parte de identificación de nubes o para predicción [42].

Las técnicas basadas en imágenes de satélites suelen ofrecer un horizonte temporal del orden de 30 minutos [35].

Un ejemplo de trabajo que emplea esta fuente de datos como método de predicción para es el presentado por Saleh en [43]. En este trabajo tiene por finalidad poder aplicar técnicas de limitación de potencia progresiva en incrementos y decrementos de la producción.

4.3.5 Predicción numérica meteorológica regional

Aunque originariamente los modelos meteorológicos numéricos de predicción (*Numerical Weather Prediction, NWP*) fueron pensados para ofrecer predicciones de las condiciones atmosférica con resolución de varias horas, se han encontrado útiles para hacer predicciones sobre la producción en parques de energías renovables (solar y eólicos), usando para ello RTMs [35]. Esto ha sido posible debido a la modularidad que presentan los modelos NWP. Aunque los modelos globales actualmente tienen una resolución que va desde los 16 a 50 km, estas salidas pueden ser de nuevo procesadas para obtener modelos locales

con una resolución más fina del rango de pocos kilómetros y con una resolución temporal que no suele ser inferior a una hora. Entre estos modelos, destacan el modelo mesoescalar norte americano (*North American Mesoscale model, NAM*) y el modelo de alta resolución de actualización rápida (*High Resolution Rapid Refresh model, HRRR*).

Los horizontes de predicción típicos con esta técnica abarcan desde unas pocas horas hasta 240h [40].

4.3.6 Modelos basados en monitorización *in-situ*

4.3.6.1 Modelos con imágenes con cámaras de cielo completo

A esta fuente de datos se le suelen aplicar las mismas técnicas que a las imágenes de satélite. Presenta la ventaja que la cámara se sitúa en la zona de interés, obteniendo una resolución superior y una cobertura circular de 15 km de radio aproximadamente. La tasa de actualización puede llegar a varios fotogramas por segundo, siendo muy superior a la que se puede obtener mediante imágenes de satélites. Las cámaras de cielo completo presentan dos desventajas principales. La primera de ella es que resulta difícil trasladar la imagen a irradiancia y la segunda deriva de que la resolución de la imagen no es constante en todo el fotograma, sino que es máximo en la vertical, y mínimo en los bordes, debido a la deformación necesaria que realiza cámara para capturar todo el cielo.

Las técnicas de predicción basadas en esta fuente de datos abarca horizontes que van desde los pocos minutos hasta 30 minutos, sin que la calidad de la predicción pierda demasiado valor [35] [40] [44]. Al igual que con las imágenes de satélite, esta fuente de datos suele usarse con técnicas como redes neuronales [45].

El uso de varias cámaras ubicadas en múltiples lugares permitiría la reconstrucción 3D de la nube y una mejor estimación de su profundidad óptica. Kurtz en [46] muestra que los problemas de perspectiva contribuyen a los errores cuando se usa una única cámara de cielo mediante simulaciones virtuales.

4.3.6.2 Modelos con redes de sensores

Ninguno de los métodos comentados hasta ahora tiene capacidad de abarcar horizontes temporales de predicción intra-minutal, sin embargo, las redes de sensores tienen potencial para cubrir estos horizontes [33].

Una red de sensores como alternativa a la tradicional medida puntual de un piranómetro tiene numerosas ventajas, aunque supone un incremento en el coste del sistema. Una medida puntual no refleja la dimensión espacio temporal del recurso solar y, por tanto, no es completamente descriptiva de la producción de una planta, como ya se comentó anteriormente.

En este sentido, las redes de sensores ofrecen información espacial de múltiples puntos, permitiendo obtener una estimación del campo de irradiancia y estudiar de forma más pormenorizada el comportamiento de la planta. Los sensores usados en este tipo de redes suelen ser piranómetros, por medir la naturaleza de interés, y específicamente, los piranómetros basados en fotodiodos por su bajo tiempo de respuesta.

4.4 Redes de sensores de irradiancia más relevantes de la literatura científica

Como se ha comentado previamente, las redes de sensores se sitúan en el punto de interés de una buena parte de la comunidad científica por numerosas razones, entre ellas, que solo las redes de sensores son capaces de monitorizar los eventos de alta variabilidad de la irradiancia y tener la capacidad de realizar predicciones intraminutales, que es una de las necesidades de los sistemas fotovoltaicos para una mayor integración en el sistema eléctrico.

Es por ello que esta tesis se centra en esta fuente de datos y es el motivo por el cual esta sección se centrará en analizar brevemente el estado del arte de las redes de sensores más relevantes.

La Tabla 4.3 resume las características principales de cada red analizada en los siguientes apartados.

Tabla 4.3: Redes de sensores de irradiancia

Ref.	Año	Periodo de muestreo	Nº pir.	Área (aprox)	¿Online? / ¿Tecnología?
[47]	2010	1 s	24	300x250 m^2 (mallada)	Sí / IEEE 802.15.4 - NI WSN
[48]	2013	100 ms	21	50x50 m^2	Si / Cableada CompactRio
[49]	2014	5 s	19	400x500 m^2 (5 edificios)	Sí / IEEE 802.15.4 - ZigBee
[50]	2014	1-10 s	19	40x35 km^2	Sí / Ethernet / Red móvil
[51]	2015	1 s	20	350x280 m^2 (mallada)	No
[52]	2016	10 s	2	200x130 m^2	Sí / IEEE 802.15.4 - NI WSN
[53]	2017	1 s	45	1.5x1.5 km^2 (mallada)	No
[54]	2017	1 s (media 1 min)	24	42x23 km^2	No

[55]	2019	1 s	5	$200 \times 200 \text{ m}^2$ (5 edificios)	Sí / LoRa
[56]	2020	5 min	10	$100 \times 50 \text{ m}^2$	Sí / IEEE 802.15.4 MAC
[57]	2021	1 s	50	$3 \times 2 \text{ km}^2$	No
[58]	2021	0.1 s	21	$25 \times 50 \text{ m}^2$	No
[59]	2022	1 s (media 1 min)	40	$200 \times 180 \text{ km}^2$	Sí / Red móvil
[60]	2022	1 s	17	$1 \times 1 \text{ km}^2$	No

4.4.1 Red de sensores de Lanai

El estudio [47] presenta una red de sensores online compuesta por 24 piranómetros muestrados a 1 segundo y cubriendo un área de unos $300 \times 250 \text{ m}^2$ en la isla de Lanai, Hawái. Los datos son enviados a través de una red mallada ZigBee empleando los módulos WSN-3212 de National Instruments. Los autores intentan caracterizar la variabilidad del recurso solar en la escala de una planta del orden de los MWs y predecir la generación fotovoltaica a partir del promediado espacial de las medidas. Debido a la tecnología empleada se encuentran dos problemas principales: desconexiones de dispositivos y ruido en el muestreo en algunos sensores.

4.4.2 Red de sensores de la Universidad Tecnológica de Tampere

Los autores de [48] estudian los efectos de la sombra parcial en una sistema fotovoltaico en el azotea del edificio de la universidad mediante una red de sensores. Se estudia el efecto de los errores según el periodo de muestreo, para ello se muestrea a 40 ms y se analiza mediante técnica de submuestreo los errores que se cometerían con una tasa más baja. Los autores concluyen que una tasa de 1 muestra cada 100 ms es suficiente para capturar los fenómenos más rápidos relacionados con la generación FV.

Con este resultado, se realiza una campaña de monitorización con una red de 21 piranómetros, con un periodo de muestreo de 100 ms. También se analiza los puntos de máxima potencia (*Maximum Power Point, MPP*) adicionales que aparecen cuando los paneles están bajo sombra parcial, y concluyen que los algoritmos convencionales de seguimiento del MPP presentan problemas en este tipo de casos.

4.4.3 Sistema de predicción solar

El estudio presentado en [49] trata de una red de 19 sensores de iluminación como alternativa de bajo coste a un piranómetro. Los sensores son ubicados en azoteas de edificios cercanos a una planta solar y se monitoriza a una tasa de una muestra cada 5 segundos. Con los datos obtenidos del sistema de monitorización, los autores desarrollan y evalúan modelos de predicción empleando técnicas basadas en redes neuronales. Se emplean los datos de producción instantánea de la planta solar como referencia para evaluar los modelos.

4.4.4 Red de sensores de Arizona

Lorenzo en [50] presenta una red de irradiancia usada para realizar predicciones con horizonte temporal en el rango de minutos y en tiempo real. La red de sensores está compuesta por 19 piranómetros muestrados a 1 segundo. Adicionalmente, se obtienen los datos de producción solar en un sistema FV en la azotea de un edificio cada 10 segundos.

La red de sensores está distribuida cubriendo un área de $40 \times 35 \text{ km}^2$ aproximadamente. Con los datos de la red de piranómetros, los autores desarrollan un modelo de predicción que validan con la producción del sistema FV. Los modelos de persistencia y cielo claro también se implementan para facilitar la comparativa. Los autores concluyen que una de las necesidades para mejorar la predicción es la obtención del vector de movimiento de nube.

4.4.5 Diseño y operación de una red de irradiancia en la planta solar de Almería

La red de sensores presentada en [51] está compuesta por 20 piranómetros cubriendo una superficie de unos $350 \times 280 \text{ m}^2$. de la planta solar de Almería. Los datos obtenidos de esta red se emplean para obtener un mapa espacial de radiación normal directa (*Direct Normal Irradiance, DNI*). Este mapa espacial se emplea para hacer predicciones, desplazándolo según el vector de movimiento de nube estimado. En este estudio, el vector de movimiento de nube se estima manualmente para varios instantes de tiempo, evidenciando la necesidad de algoritmos de estimación del CMV.

4.4.6 Sistema de monitorización en tiempo real para una planta fotovoltaica

Moreno en [52] desarrolla una red de sensores para monitorizar en tiempo real parámetros relativos a la producción y calidad de la energía de una planta fotovoltaica. Incluye 2 sensores de radiación solar situados en el plano de los paneles para medir el GTI. Para la monitorización se usan equipos de National Instruments: una red inalámbrica basada en nodos WSN3226 y gateways WS9795, cuatro Compact Rio en modo esclavo, cada una en un inversor y una

Compact Rio en modo maestro que coordina las otras cuatro, y gestiona la red inalámbrica.

Los nodos inalámbricos toman 22 medidas de corriente continua, 6 medidas de temperatura de los paneles y medidas de los 2 piranómetros.

4.4.7 Método de kriging para estimar la variabilidad en una potencial planta FV

El trabajo presentado por Monger en [53] emplea una red de sensores de 45 piranómetros muestreados cada segundo y almacenado en un registrador de datos. Los sensores cubren un área aproximada de $1.5 \times 1.5 \text{ km}^2$ en una disposición mallada, tal y como puede observarse en la figura 4.2.

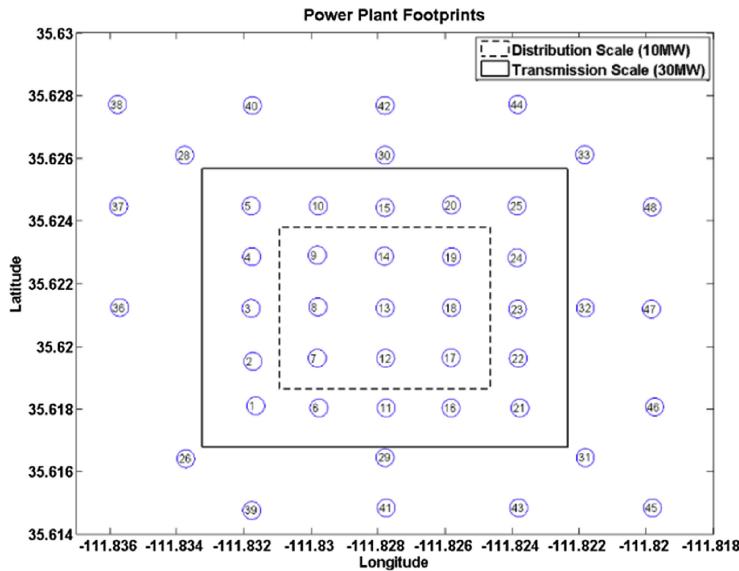


Figura 4.2: Red de sensores empleada en el estudio de Monger [53]

Los datos obtenidos son procesados mediante el método de kriging, que es un conocido método geoestadístico para realizar interpolaciones espaciales. Se aplica la media a la interpolación espacial y se compara este resultado con la respuesta de una hipotética planta de 30 MW. El estudio también analiza superficialmente la variabilidad de la irradiancia media en función del número de sensores empleados.

El sistema de recogida de datos tiene la carencia de no enviar los datos en línea, por lo que no pueden hacerse estimaciones en tiempo real.

4.4.8 Red de monitorización de irradiancia para evaluación de sistemas fotovoltaicos y predicciones locales

Yang en [54] presenta un sistema de monitorización de irradiancia para la evaluación y predicción de sistemas fotovoltaicos. Para ello emplea datos de una red de monitorización existente formada por 24 estaciones en Singapur cubriendo un área aproximada de $42 \times 23 \text{ km}^2$ con una distribución irregular. Este sistema mide la radiación global horizontal (GHI) cada segundo, pero almacena en los registros la media minutal.

Con los datos de obtenidos el autor analiza la correlación entre distintas estaciones, obteniendo mapas en espacio-D, que refleja la correlación espacial entre estaciones. El autor también estudia como se ve alterado el espacio-D cuando se añaden o se eliminan estaciones.

En este estudio, al igual que en el anterior (sección 4.4.7), se emplea una red de sensores que no emite los valores en tiempo real, presentando su utilidad únicamente como fuente de información para análisis estadístico y desarrollo de algoritmos, pero no como fuente de datos para realizar predicciones en tiempo real.

4.4.9 Red de sensores para la predicción a corto plazo de potencia FV

El trabajo [55] presenta una red formada por 5 sensores basados en células solares y desplegados en las azoteas de edificios cubriendo un área aproximada de $200 \times 200 \text{ m}^2$ muestrados a una tasa de 1 s. Se usa un sensor adicional para estimar la generación de un sistema FV de 5 MW. Los autores presentan un método de predicción basado en el reconocimiento de dos escenarios diferentes, llamados escenario estacionario y escenario rampa. En base a los escenarios reconocidos se realizan predicciones usando diversas estrategias a modo de estudio comparativo.

En este estudio se propone una estrategia de control de potencia FV sin usar baterías y aprovechando la predicciones a corto plazo realizadas.

4.4.10 Red de Irradiancia solar para análisis y medida

El estudio [56] desarrolla una red de 25 sensores en azoteas de edificios, aunque solo 10 de ellos cuentan con sensores de radiación solar. Como estándar de comunicación se usa el IEEE 802.15.4 MAC. Los datos de irradiancia son registrados y mandados cada 5 minutos y cubren un área aproximada de $100 \times 50 \text{ m}^2$.

Con los datos obtenidos se implementa una sistema de predicción de irradiancia usando un modelo autorregresivo de media móvil.

4.4.11 Modelo de nubes de advección

Los autores de [57] modelan el suavizado producido por la agregación espacial mediante un modelo al que llaman nubes de advección. Para ello, emplean los datos de 50 sensores de irradiancia que cubren una área aproximada de $3 \times 2 \text{ km}^2$, estando 26 de ellos en una zona más densificada, cubriendo un área de $400 \times 200 \text{ m}^2$, como se muestra en la Figura 4.3. Los sensores se muestran cada segundo y se almacena en un registrador de datos (*data logger*) local, sin posibilidad de acceder a ellos de forma remota. Este modelo presenta mejoras sobre otros métodos de estimación del agregado espacial, pero precisa conocer el CMV.

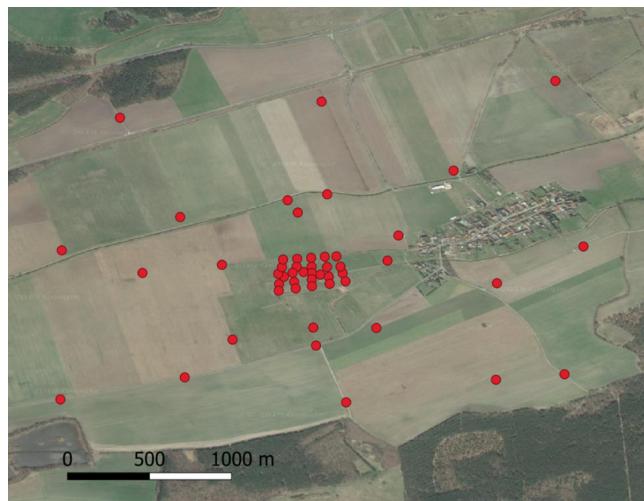


Figura 4.3: Distribución de la red de sensores empleadas en el estudio de modelo de nubes de advección.

4.4.12 Estudio de las características del punto de máxima potencia de paneles parcialmente sombreados

El estudio presentado en [58] está muy relacionado con el presentado en la sección 4.4.2. Este estudio se desarrolla en la planta FV de investigación de la universidad de Tampere, que se ubica en la azotea del edificio y tiene por objetivo estudiar el comportamiento de las curvas de máxima potencia bajo condiciones de sombreado no uniforme. Para ello se monitoriza la curva I-V de tres líneas (*strings*) de paneles fotovoltaicos en días parcialmente cubiertos. Adicionalmente, se recogen datos de irradiancia con 21 piranómetros, estando 19 de ellos colocados en los paneles de las líneas analizadas. Los piranómetros se muestran a una tasa de 10 Hz, mientras que la curva I-V de los paneles se hace a 1 Hz. Los autores no indican si los datos se transmiten en tiempo real o son almacenados para estudios.

4.4.13 Red de monitorización de irradiancia en el sur de Alemania

La red de monitorización de [59] está formada por 40 estaciones de medida cubriendo un área aproximada de $200 \times 180 \text{ km}^2$, con una distancia entre estaciones cercanas que varía desde los 15 a los 35 km. Los datos de irradiancia se muestrean cada segundo aunque el dato trasmisido en tiempo real es la media minutal.

Los autores caracterizan los sitios mediante inteligencia artificial, implementan detección de escenarios (nieve, hielo y agua) y analizan la consistencia de los datos mediante diversos controles de calidad automáticos y manuales.

4.4.14 Control de plantas fotovoltaicas para la mitigación de la variabilidad de la generación

En el estudio [60] se diseña un servicio que indique a las plantas fotovoltaicas la limitación de potencia necesaria en la generación para reducir la variabilidad en la producción. Para ello emplea 17 estaciones que cubren un área de $1 \times 1 \text{ km}^2$ a una tasa de 1 segundo por muestra alrededor del aeropuerto de Oahu, Hawaii. Una representación de la distribución de la red se puede observar en la Figura 4.4. Los datos obtenidos de estas estaciones son correlacionados entre sí para la toma de decisiones, agrupamiento de sensores y desarrollar una estructura de control y algoritmo para la estimación de la limitación de potencia necesaria, probándose en plantas FV simuladas.



Figura 4.4: Distribución de los 17 sensores de irradiancia alrededor del aeropuerto en Oahu, Hawaii.

CAPÍTULO 5

Discusión conjunta de los resultados

Esta tesis doctoral tiene como meta principal el desarrollo y validación de una red de sensores de monitorización de irradiancia con las capacidades necesarias para ser empleada como una fuente de datos para sistemas de predicción a corto plazo de la irradiancia solar, y de este modo, una fuente de información operacional para plantas FV.

Para alcanzar esta meta general, se han cumplido una serie de objetivos específicos mediante publicaciones. La tabla 3.2 muestra la correspondencia entre las publicaciones y estos objetivos específicos.

Los resultados obtenidos en el desarrollo de esta tesis quedan recogidos en tres artículos publicados en los primeros dos primeros cuartiles¹ de revistas científicas indexadas en el Journal Citations Reports.

Esta tesis está presentada en el formato de compendio de publicaciones, cumpliendo con todos los requisitos establecidos por la Escuela de Doctorado de la Universidad de Cádiz, detallándose a continuación la información más relevante de los artículos que conforman este compendio.

Artículo 1 (Apéndice I)

Título: An on-line low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV system

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, Juan José González de la Rosa, José Carlos Palomares-Salas y José María Sierra-Fernández

Revista, año y EISSN: Sensors (2018) 1424-8220

DOI: <https://doi.org/10.3390/s18103405>

Factor de impacto JCR 2018: 3.031

¹ Tomando como referencia para el artículo de 2022, el cuartil de 2021

Posición de la revista según área JCR en 2018:

- **Instruments & Instrumentation:** 15/61 (Q1)
- **Electrochemistry:** 12/26 (Q2)
- **Cheministry, analytical:** 23/84 (Q2)

Abstract

Very short-term solar forecasts are gaining interest for their application on real-time control of photovoltaic systems. These forecasts are intimately related to the cloud motion that produce variations of the irradiance field on scales of seconds and meters, thus particularly impacting in small photovoltaic systems. Very short-term forecast models must be supported by updated information of the local irradiance field, and solar sensor networks are positioning as the more direct way to obtain these data. The development of solar sensor networks adapted to small-scale systems as microgrids is subject to specific requirements: high updating frequency, high density of measurement points and low investment. This paper proposes a wireless sensor network able to provide snapshots of the irradiance field with an updating frequency of 2 Hz. The network comprised 16 motes regularly distributed over an area of 15 m × 15 m (4 motes × 4 motes, minimum intersensor distance of 5 m). The irradiance values were estimated from illuminance measurements acquired by lux-meters in the network motes. The estimated irradiances were validated with measurements of a secondary standard pyranometer obtaining a mean absolute error of 24.4 W/m² and a standard deviation of 36.1 W/m². The network was able to capture the cloud motion and the main features of the irradiance field even with the reduced dimensions of the monitoring area. These results and the low-cost of the measurement devices indicate that this concept of solar sensor networks would be appropriate not only for photovoltaic plants in the range of MW, but also for smaller systems such as the ones installed in microgrids.

Artículo 2 (Apéndice II)

Título: Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José-Carlos Palomares-Salas, Juan-José González-de-la-Rosa, José-María Sierra-Fernández, Olivia Florencias-Oliveros

Revista, año y EISSN: Solar Energy (2020) 1471-1257

DOI: <https://doi.org/10.1016/j.solener.2020.03.081>

Factor de impacto JCR 2020: 5.742

Posición de la revista según área JCR en 2020:

- Energy & Fuels: 38/114 (Q2)

Abstract

Small-scale PV generation is particularly affected by the irradiance variability produced by cloud shadows. Accurate predictions of the clouds passing over the PV field are thus necessary for the optimized management and integration of this renewable power source. Two main elements are required to perform these predictions: the local irradiance field and the cloud motion vector. Irradiance sensor networks are positioning as a promising data source at the spatial and temporal scales of the problem, avoiding the irradiance inference problems and costs of image-based instrumentation. This paper proposes a method to infer the cloud shadow motion vector from small-scale irradiance sensor networks data. The method does not require specific network configuration or layout, and the algorithm is computationally simple: graphical solutions are obtained by aggregating mean absolute errors in a diagram/matrix with each element representing a possible displacement of the cloud shadows. The validation is conducted with a fractal cloud model that allows the generation of irradiance time series according to an arbitrary cloud motion vector. The most correlated pair and the linear cloud edge methods are used for benchmarking purposes. Gridded and non-gridded sensors layouts are tested with number of sensors ranging from 9 to 100, monitored areas from 100 to 10000 m², and sampling periods from 0.3 to 3.3 s. The results show the superiority of the proposed method with a reduction of 50–90 % of the root mean square errors respect to the benchmark methods in 75 % of the tests. Additionally, the proposed method maintains similar performance as sampling rate decreases, while the benchmark methods exhibit worsening results.

Artículo 3 (Apéndice III)

Título: Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José María Sierra-Fernández, Juan José González de-la-Rosa, José Carlos Palomares-Salas y Olivia Florencias-Oliveros

Revista, año y EISSN: Sensors (2022) 1424-8220

DOI: <https://doi.org/10.3390/s22082928>

Factor de impacto JCR 2021: 3.847

Posición de la revista según área JCR en 2021:

- Instruments & Instrumentation: 19/64 (Q2)
- Chemistry, analytical: 29/87 (Q2)

- Engineering, Electrical & Electronic: 95/276 (Q2)

Abstract

Cloud-induced photovoltaic variability can affect grid stability and power quality, especially in electricity systems with high penetration levels. The availability of irradiance field forecasts in the scale of seconds and meters is fundamental for an adequate control of photovoltaic systems in order to minimize their impact on distribution networks. Irradiance sensor networks have proved to be efficient tools for supporting these forecasts, but the costs of monitoring systems with the required specifications are economically justified only for large plants and research purposes. This study deals with the design and test of a wireless irradiance sensor network as an adaptable operational solution for photovoltaic systems capable of meeting the measurement specifications necessary for capturing the clouds passage. The network was based on WiFi, comprised 16 pyranometers, and proved to be stable at sampling periods up to 25 ms, providing detailed spatial representations of the irradiance field and its evolution. As a result, the developed network was capable of achieving comparable specifications to research wired irradiance monitoring network with the advantages in costs and flexibility of the wireless technology, thus constituting a valuable tool for supporting nowcasting systems for photovoltaic management and control.

A continuación se presenta una discusión conjunta por cada uno de los objetivos propuestos en la sección 2.2. Información más detallada de cada uno de los artículos puede ser consultada en su correspondiente apéndice.

5.1 Objetivo 1: Revisión del estado del arte de las redes de sensores de monitorización de irradiancia

Este objetivo es un requisito previo que se realiza antes de comenzar la fase experimental de la tesis, y que condiciona la toma de decisiones de los desarrollos. Este objetivo se revisa y actualiza en múltiples ocasiones durante el desarrollo de esta tesis, quedando plasmado en la introducción de los artículos de los Apéndices I, II y III.

La Tabla 1 del artículo del Apéndice III (similar a la Tabla 4.3 de este documento) resume las principales características de las redes de sensores de irradiancia más relevantes de la literatura científica: Periodo de muestreo, número de sensores, área cubierta, tecnología empleada y si transmiten sus datos en tiempo real. Es remarcable en este punto que las redes de sensores aquí recogidas con un periodo de muestreo inferior a 1 segundo no transmiten sus datos en tiempo real, excepto la red desarrollada en el artículo del Apéndice I.

5.2 Objetivo 2: Revisión del estado del arte de los algoritmos de estimación de dirección y velocidad de la nube con redes de sensores

Este objetivo queda parcialmente plasmado en la introducción del artículo del Apéndice II, denominado: “Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method”.

A continuación se presentan los métodos con redes de sensores más relevantes de la bibliografía científica:

5.2.0.1 Algoritmos de estimación del CMV con redes de sensores más relevantes

Algunos autores han usado redes de sensores para estimar el CMV usando métodos analíticos como la correlación cruzada (*cross correlation*) de las series de irradiancia obtenidas y métodos similares a los aplicados en cámaras de cielo completo. Algunos ejemplos de ellos son los trabajos publicados [61], [62], [63], [64] y [49].

Como ejemplo de ello, Bosch en [61] y [62], que desarrolla dos métodos de estimación del CMV mediante análisis analítico de las series temporales de irradiancia obtenidas con una red de sensores. El primero de ellos, llamado Par Más Correlacionado (*Most Correlated Pair, MCP*) y desarrollado en [61], es un método relativamente sencillo que usa una estructura semicircular de 6 metros de radio con 7 sensores como se muestra en la Figura 5.1. Este método parte de la premisa que las series temporales de irradiancia del par de sensores alineados con el movimiento de la nube estarán altamente correlacionados con un tiempo de retraso t_{ab} . Se asume que la dirección del movimiento es la del par más correlacionado y la velocidad se estimada mediante la ecuación 5.1.

$$v = \frac{D}{t_{MCP}} \quad (5.1)$$

donde D es la distancia entre los sensores más correlacionados.

Este mismo método es desarrollado por Bosch en [62], recibiendo el nombre de Método de Correlación Cruzada, empleando como datos de irradiancia los datos de generación de los inversores.

El segundo método es también planteado en el trabajo [61]. Se desarrolla usando tres sensores que forman un ángulo recto entre ellos de modo similar al presentado en la Figura 5.2a. Este trío de sensores se puede obtener de la configuración 5.1 si se selecciona el sensor central y los correspondientes a 0° y 90° o el central y cualquier otra pareja que forme 90° . En este caso, la ecuación 5.1 no se puede aplicar, ya que rara vez el desplazamiento de las nubes coincidirá con alguno de los dos ejes rectos. Para resolver esto, Bosch plantea una serie

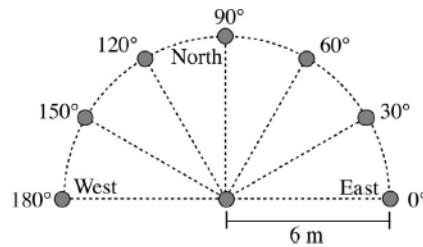


Figura 5.1: Estructura de piranómetros usadas para el método MCP. Fuente [61]

de ecuaciones asumiendo que el frente de nube es recto y por ello, este método recibe el nombre de Borde de Nube Recto (Linear Cloud Edge, LCE). Esta hipótesis es aceptable para escalas pequeñas, donde distancias entre sensores son relativamente cortas. Bosch generaliza este método en [62], donde el trío de sensores puede formar un ángulo genérico (Figura 5.2b).

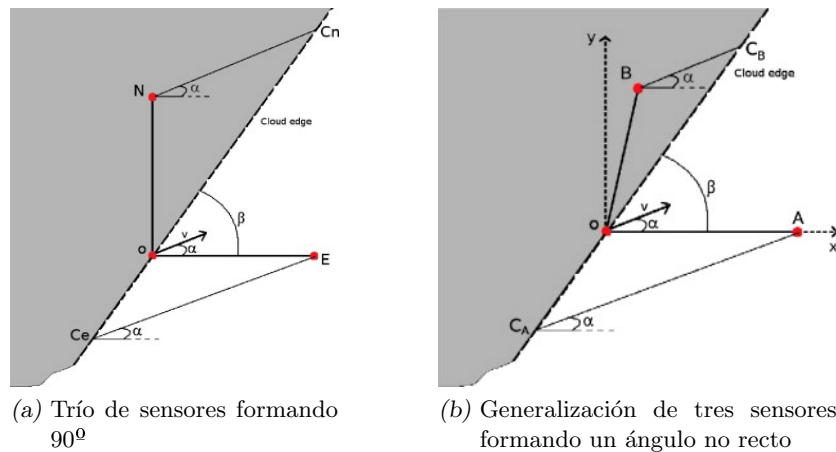


Figura 5.2: Representación de los tres sensores para el desarrollo del algoritmo LCE, (a) para la particularización de ángulo recto, (b) generalización para cualquier ángulo. Figuras obtenidas de [61] y [62]

Smithpeter en [63] desarrolla un sistema IoT en tiempo real para la estimación del CMV y se dispone como se muestra en la Figura 5.3. El autor propone en este trabajo el método correlación cruzada simple (*Simplex Cross-Correlation Method, SCM*). Este método es un método analítico y también parte de la hipótesis que el borde de nube es recto sobre el conjunto de sensores. El método propuesto por el autor es comparado con el MCP.

El trabajo [64] presenta un sistema para estimar el CMV usando nueve sensores en disposición circular con un sensor en el centro como se muestra en la Figura 5.4. Los valores medidos se transforman en una matriz de 3x3 y es



Figura 5.3: Disposición de sensores empleada para el método del SCM. Fuente [63]

procesado del mismo modo que en análisis de imagen, empleando el método de la matriz del gradiente (*Gradient Matrix Method*).

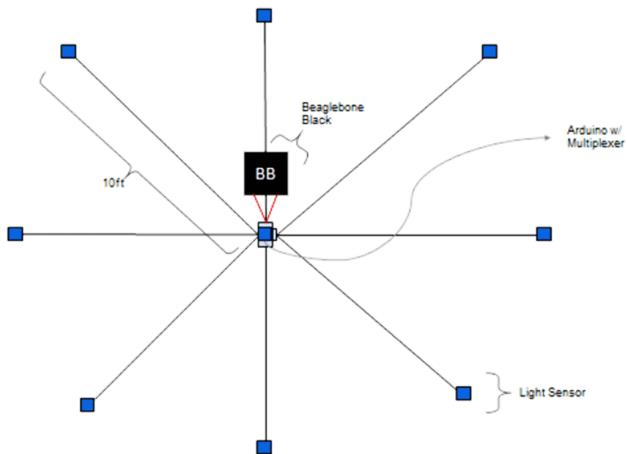


Figura 5.4: Disposición de sensores empleadas por el método de la matriz del gradiente. Fuente [64]

El trabajo presentado por Achleitner en [49] no se puede considerar un sistema de predicción operacional. Aunque muestrea los niveles de irradiancia obtenidos por sensores y recoge valores de producción de la planta solar en tiempo real, estos datos son almacenados para modelar y validar un sistema de predicción a corto plazo en diferido. Para ello, usa como CMV la dirección y velocidad del viento ofrecida por la base de datos de la NOAA (*North Oceanic and Atmospheric Administration*).

Por último, es importante tener en cuenta que para una red de sensores cubriendo un área y a una frecuencia de muestreo dada, existe una limitación en la velocidad de la nube detectable. Para el diseño y configuración de los nodos

de la red es necesario tener en cuenta la velocidad máxima de las nubes, que puede ser considerada en 50 m/s, ya que velocidades superiores son eventos muy poco comunes [65].

5.3 Objetivo 3: Estudio de luxómetros y piranómetros como fuente de información para la monitorización del recurso solar

Este estudio se realiza en el artículo del Apéndice I, desarrollando una red de sensores donde se usa información de iluminación como alternativa a datos de irradiancia solar. Para ello, se empleó un piranómetro como patrón de calibración como se resume a continuación.

El apartado 3 de dicho artículo describe el proceso de inferencia entre los sensores usados en los nodos y el piranómetro secondary-standard que se usa como patrón de calibración.

Los datos arrojados en este proceso son prometedores, obteniéndose coeficientes de correlación entre 0.975 y 0.991, con una desviación estándar (SD) por debajo de los 50 W/m^2 , y un Error Absoluto Medio (MAE) inferior a los 27 W/m^2 . La tabla completa con los estadísticos de cada uno de los nodos se puede ver en la Tabla 5.1

Tabla 5.1: Estadísticos de la calibración de los nodos desarrollados en el artículo del Apéndice I

	MAE (W/m^2)	SD (W/m^2)	R
Nodo #1	24.4	40.4	0.983
Nodo #2	24.8	38.4	0.984
Nodo #3	26.9	36.9	0.986
Nodo #4	24.8	39.0	0.984
Nodo #5	25.3	36.5	0.983
Nodo #6	20.7	32.8	0.986
Nodo #7	20.2	29.3	0.991
Nodo #8	23.7	38.8	0.984
Nodo #9	25.2	39.9	0.983
Nodo #10	21.1	27.6	0.990
Nodo #11	25.6	40.9	0.982
Nodo #12	16.0	25.4	0.991
Nodo #13	18.5	30.0	0.991
Nodo #14	32.2	47.3	0.976
Nodo #15	35.3	48.6	0.975
Nodo #16	25.6	38.6	0.984

Otro resultado interesante es el que extrae de los diferentes análisis realizados durante un evento de sobre-irradiancia, Figura 5.5. Los tiempos de respuesta de ambos sensores (medida y patrón de calibración) son notablemente diferentes, dejando en evidencia que el piranómetro usado tiene un comportamiento lento para poder analizar eventos rápidos de irradiancia.

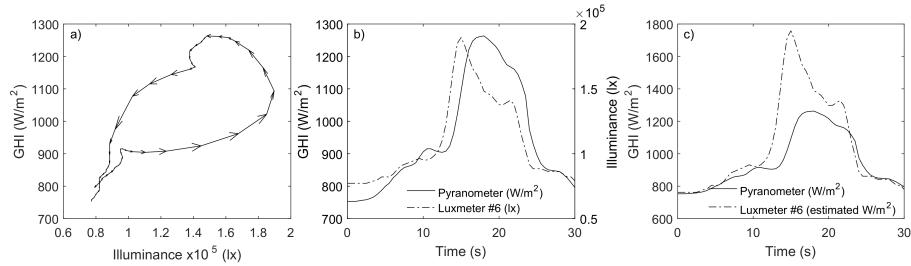


Figura 5.5: Análisis durante un evento de sobre-irradiancia: a) Trayectoria en un diagrama de dispersión, b) Comparación en el dominio del tiempo, c) Comparación de la estimación y la medida de irradiancia.

Se debe tener en cuenta que los datos presentados en la Tabla 5.1 y las distribuciones de errores agregadas e individuales de la Figura 5.6 es una caracterización conservativa, puesto que incluyen desviaciones derivadas de las diferencias de tiempo de respuesta de los sensores y el patrón de calibración.

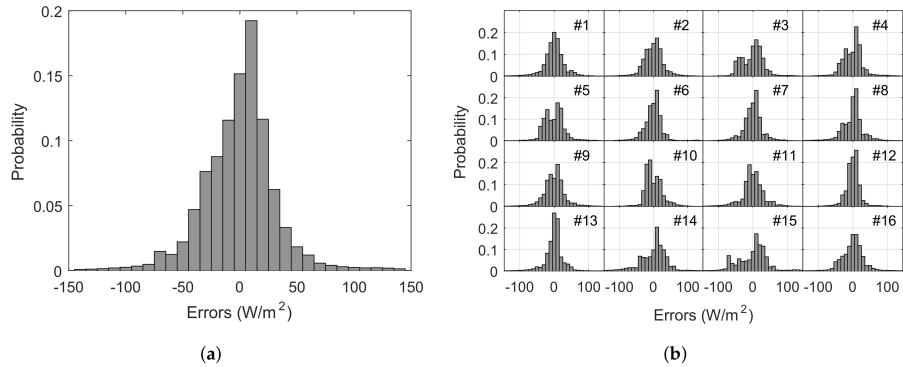


Figura 5.6: a) Distribución agregada de errores. b) Distribución de errores de cada nodo.

De los resultados anteriores se puede inferir que los luxómetros podrían ser una alternativa económica a los piranómetros, aunque sería necesario realizar un nuevo estudio empleando un piranómetro de fotodiodo por tener un tiempo de respuesta más rápido.

5.4 Objetivo 4: Estudio y caracterización de sistemas de comunicaciones con tecnología inalámbrica y adecuados para sistemas de monitorización de irradiancia enfocados a predicción a corto plazo.

Este objetivo es un requisito previo para el desarrollo de las redes de sensores descritas en los artículos de los Apéndices I y III. La Tabla 2 y Tabla 3 del artículo del Apéndice III se muestra un resumen de las características de mayor interés de las principales tecnologías inalámbricas y protocolos de la capa de aplicación para redes de sensores.

Las tecnologías inalámbricas también quedan recogidas la Tabla 5.2 de este documento de tesis, y los protocolos de capa de aplicación en la Tabla 5.3. La pareja de esta elección determina las características en las comunicaciones de la red de sensores.

En los artículos de los Apéndices I y III se caracterizan las redes desarrolladas.

5.4.1 Apéndice I

Este artículo desarrolla una red de sensores basada en ZigBee y cuya descripción más detallada se puede encontrar en la Sección 5.5.

A continuación se describe la caracterización del rendimiento de la misma.

5.4.1.1 Análisis de Rendimiento

Este análisis se puede encontrar en la sección 4 del artículo presentado en el Apéndice I. A pesar de que ZigBee es una tecnología que por especificaciones teóricas podría ser candidata para el desarrollo de una red de sensores de irradiancia, presenta ciertos inconvenientes en la aplicación real.

Con la red de 16 sensores desarrollada con esta tecnología se encontró problemas para superar la tasa de 1 muestra por segundo debido a inestabilidades, irregularidad en la recepción y pérdidas de paquetes. Con optimizaciones en los nodos y la inclusión de dispositivos adicionales (enrutadores) en la red que actuaran como intermediarios entre los nodos y el coordinador de la red (dispositivo que recibe toda la información de los nodos), la red mejoró pero no lo suficiente para alcanzar las especificaciones deseadas. La Figura 5.7 muestra el rendimiento de la red para diferentes configuraciones con variable número de enrutadores para tasas de muestreos por debajo del segundo.

El ratio de paquetes recibidos-enviados, es indicador de la pérdida de paquetes. Un ratio de 1 implica que todos los paquetes enviados han sido recibidos.

La desviación estándar del tiempo de muestreo cuantifica la dispersión

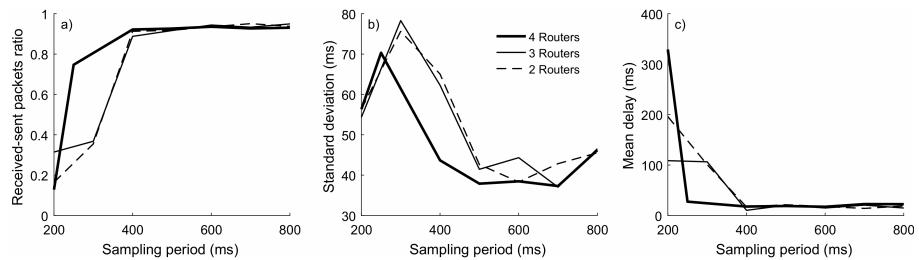


Figura 5.7: Rendimiento de la red bajo diferentes configuraciones a) Ratio de paquetes recibidos-enviados b) Desviación estándar del tiempo muestreo respecto al periodo de muestreo solicitado, c) Retraso medio del paquete sobre el muestreo solicitado.

temporal de los paquetes recibidos, de este modo, una baja desviación estándar está asociada con un alta regularidad del muestreo, indicando un flujo estable de información desde los nodos al coordinador.

El retraso medio en la recepción de paquetes está asociado con el tiempo de computación y posibles retrasos de la transmisión, que se añaden al periodo de muestreo de cada nodo. Teniendo en cuenta esto, el periodo de muestreo se puede ajustar teniendo en cuenta el retraso, de modo que se consiga un periodo de muestreo más cercano al deseado.

Los resultados de la Figura 5.7 muestra que periodos de muestreo más cortos de 400 ms implican una tasa de pérdida de paquetes importante e introduce una dispersión temporal y retraso en los paquetes recibidos.

5.4.2 Apéndice III

En el artículo del Apéndice III se desarrolla una nueva red de sensores, esta vez con tecnología WiFi. A continuación se detallan los diseños de las pruebas de rendimiento y el análisis de la misma. Una descripción más detallada de esta red se puede leer en la Sección 5.5.

A continuación se describe la caracterización del rendimiento de la misma.

5.4.2.1 Diseño del test de rendimiento

El test de rendimiento está enfocado en caracterizar la estabilidad de la red, la sincronización de los datos y la eficiencia del proceso de almacenamiento. Los nodos son programados para tomar una muestra y enviarla por la red a intervalos de tiempo regulares. Este tiempo es controlable mediante el protocolo MQTT.

Los ESP32 tienen la capacidad de realizar sincronización con un servidor

NTP (*Network Time Protocol*). Gracias a ello, se puede referenciar de forma absoluta los datos muestreados para una mejor trazabilidad. Como servidor NTP se usa un GMR5000 de *Masterclock Inc.* que es un servidor NTP local, Figura 5.8.



Figura 5.8: Servidor NTP local GMR5000 de *Masterclock Inc.*

Se envía el tiempo con precisión de milisegundos en formato Unix, junto con el valor obtenido en leído del piranómetro, para contextualizar temporalmente el dato. De este modo, se puede tasar la capacidad de los nodos de muestrear a intervalos definidos de tiempo.

En el lado del servidor, cada paquete de información recibido se almacena junto con el tiempo de recepción con precisión de milisegundos. De este modo, se puede analizar la estabilidad de la recepción.

El ratio de paquetes perdidos se puede calcular como la cantidad de paquetes no recibidos sobre los esperados, que es otro aspecto para caracterizar la estabilidad de la red. Los paquetes esperados se calculan teniendo en cuenta la duración y la tasa de muestreo de dicha prueba.

Debido a que los datos operaciones para la gestión de plantas fotovoltaicas y técnicas de predicción a corto plazo requieren muestreo por debajo del segundo, estas pruebas se realizan con los siguientes períodos de muestreo: 500, 300, 200, 100, 50, 25 y 10 ms, con una duración de 600 s por cada periodo de muestreo.

Se probaron dos sistemas de adquisición para estas pruebas, y que se describen con más detalle en la sección 5.6.

5.4.2.2 Resultados de las pruebas de rendimiento

Estos resultados son la validación de que el funcionamiento de la red diseñada junto con el sistema de adquisición cumple con las especificaciones requeridas. Tal y como se definió anteriormente, se analizó la estabilidad del muestreo y recepción, y el ratio de paquetes perdidos, ofreciendo una caracterización del rendimiento de la red para cada estado de operación.

La Figura 5.9 corresponde a los histogramas de muestreo agregados de la red (16 nodos) para cada uno de los períodos de muestreo probados. De esta figura se puede observar que los nodos presentan un comportamiento de muestreo excelente.

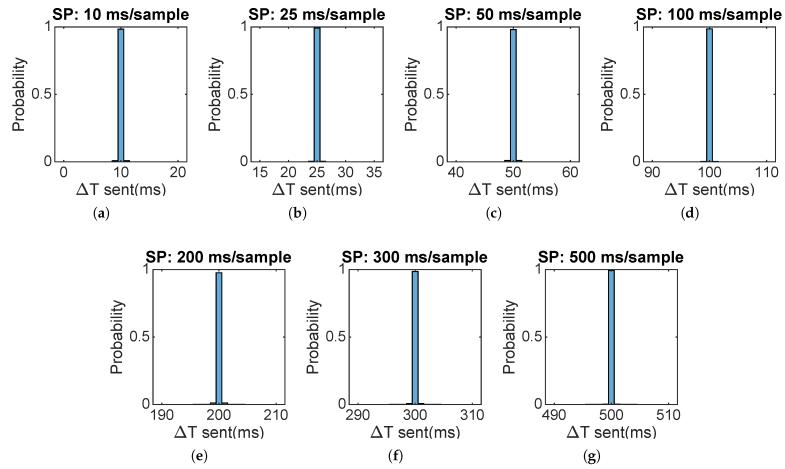


Figura 5.9: Histogramas agregados de envío para cada periodo de muestreo probado. Cada periodo de muestreo (*Sampling Period, SP*) es indicado en el título de los histogramas.

La estabilidad de la red caracteriza como se transmiten los paquetes muestreados por la red, para ello, se analizan los tiempos de recepción entre paquetes consecutivos del mismo dispositivo. Este análisis arroja la Figura 5.10. Se puede observar que el histograma asociado al periodo de muestreo de 10 ms presenta una distribución bimodal. De esta distribución se puede inferir que los paquetes retrasados solapan en el tiempo con los siguientes, por tanto, no se puede asumir que el tiempo de recepción sea representativo de la muestra cuando el periodo de muestreo está en este rango. Para el resto de periodos de muestreo, la desviación temporal se mantiene en el rango de ± 10 ms, con una desviación media de 0 ms.

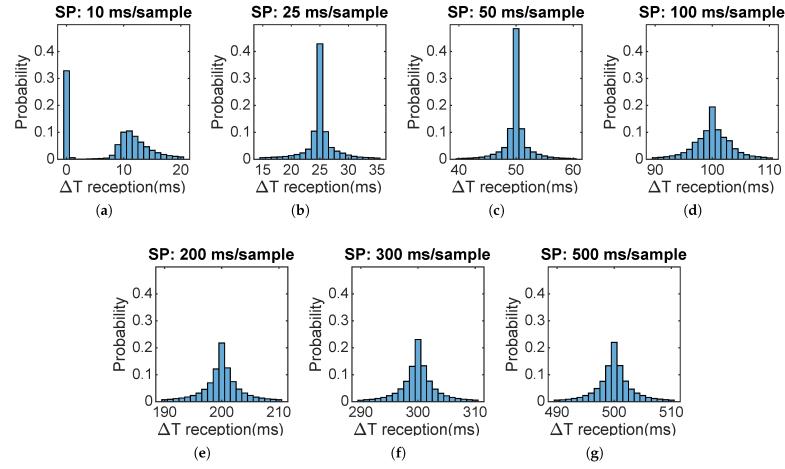


Figura 5.10: Histogramas de recepción para cada periodo de muestreo (SP) probado, que es indicado en el título de los histogramas.

El otro aspecto analizado del rendimiento de la red es el ratio de la perdida de paquetes. Este aspecto ofrece una cuantificación de los paquetes que no alcanzan el final del flujo de datos. Las causas de estas perdidas pueden ser diversas: paquetes no enviados por el nodo, desconexiones del nodo, paquetes perdidos en la red WiFi o datos no procesados apropiadamente por el servidor. La Figura 5.11 muestra el ratio de la pérdida de paquetes frente al periodo de muestreo. En dicha figura no se aprecia correlación entre el periodo de muestreo y las pérdidas de paquetes, que se mantienen por debajo del 0.45 % para todos los períodos de muestreo probados. Un valor tan bajo no tiene impacto relevante para los propósitos de la red.

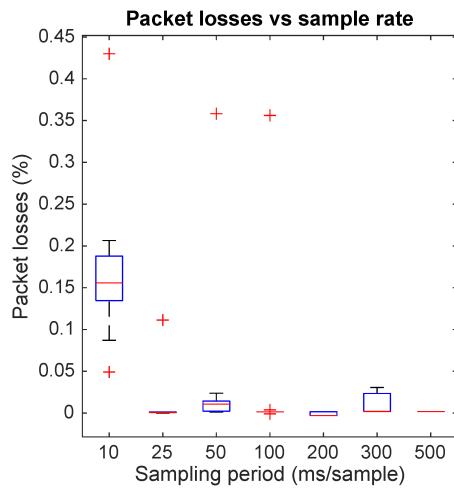


Figura 5.11: Ratio de pérdidas de paquetes frente al periodo de muestreo de la prueba.

5.5 Objetivo 5: Desarrollo y validación de una red de sensores de bajo coste para la monitorización de irradiancia.

Este objetivo son los fines principales de los trabajos presentados en los Apéndices I y III, que se detalla a continuación:

5.5.1 Apéndice I

En este trabajo se desarrolla una red inalámbrica de 16 sensores de iluminación con una estructura mallada de 4x4 cubriendo un área de 15 m x 15 m. La tecnología de comunicaciones empleada para desarrollo de los nodos es ZigBee. El esquemático y aspecto final se puede ver en la Figura 5.12.

Se emplea un único piranómetro como patrón de calibración, como se ha comentado en la sección 5.3.

5.5.1.1 Resultados

Los resultados presentados en este artículo muestra las virtudes de la red desarrollada, a pesar de las limitaciones ya descritas. La figura 5.13 muestra el comportamiento de la red en series temporales, donde se aprecia la similitud de todos los nodos.

La Figura 5.14 muestra una secuencia de 60 segundos de evolución del campo de irradiancia estimado, ofreciendo de este modo otro punto de vista del funcionamiento continuo del sistema. Esta secuencia incluye condiciones despejadas y nubladas.

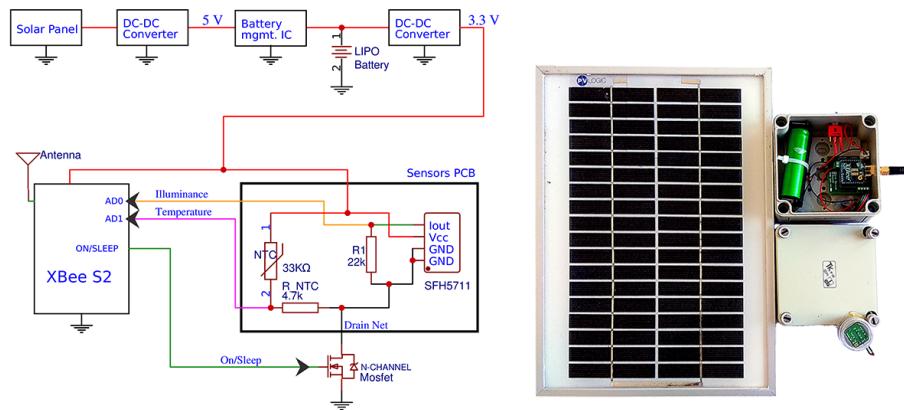


Figura 5.12: Esquemático y aspecto final del nodo ZigBee desarrollado en el artículo del Apéndice I

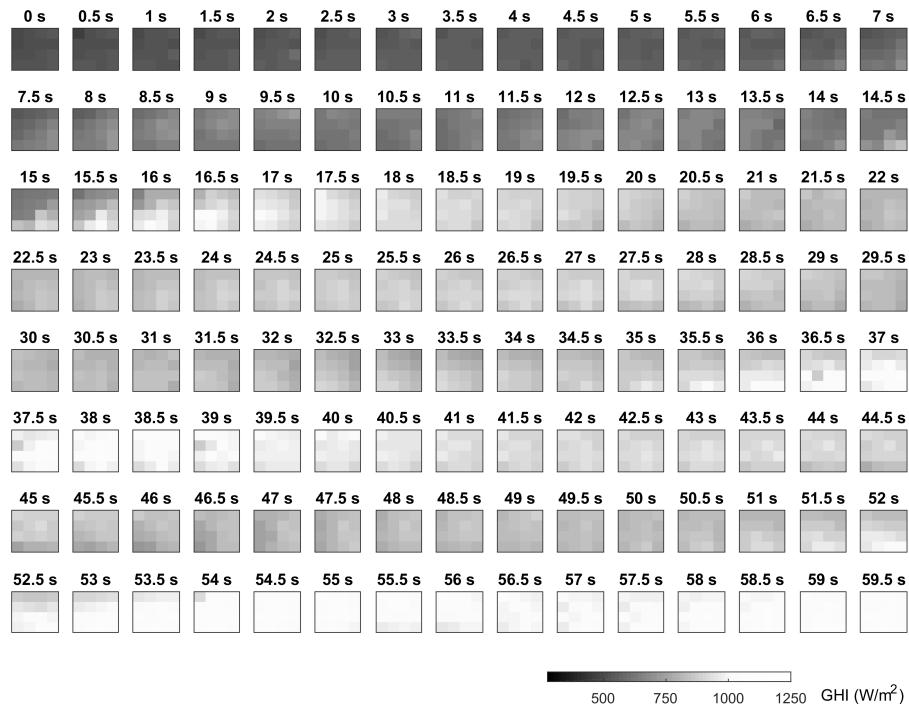


Figura 5.14: Secuencia de 60 segundos del campo de irradiancia.

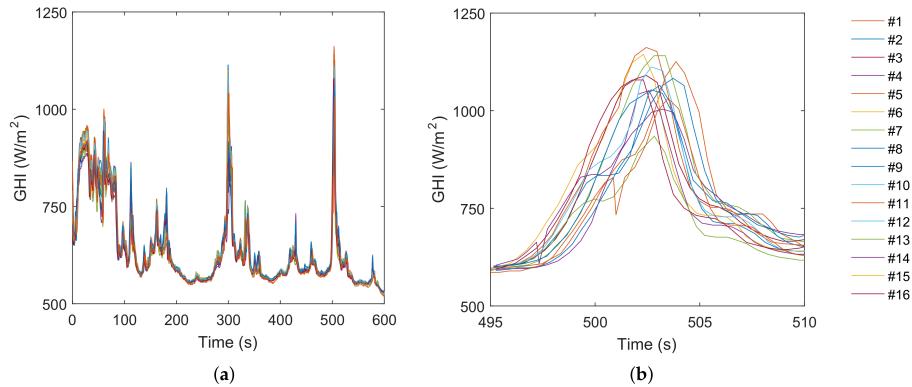


Figura 5.13: Irradiancia estimada por los 16 nodos: a) ventana de 10 minutos de duración, b) detalle de 15 segundos.

5.5.2 Apéndice III

La sección de análisis de rendimiento del artículo del Apéndice I mostró ciertas limitaciones en la capacidad de muestreo de la red de sensores desarrollada con ZigBee. Estas limitaciones distan de los requisitos indicados por Torres Lobera en [48], en el que especifica que una tasa de muestreo de 100 ms es suficiente para capturar los fenómenos más rápidos de irradiancia relacionados con la generación de energía. La red de sensores presentada en el Apéndice I no es escalable en cantidad de sensores sin sacrificar la tasa de muestreo, por ello, en el artículo del Apéndice III se desarrolla y valida mediante pruebas, una nueva red de sensores con otra tecnología de comunicaciones.

5.5.2.1 Protocolos de comunicaciones

La selección de del protocolo de comunicaciones se realiza en base a las tecnologías inalámbricas más comunes en el marco del Internet de las Cosas (IoT), ver Tabla 5.2.

Tabla 5.2: Comparativa de tecnologías IoT para una red de sensores inalámbrica

Tecnología	Bluetooth	LoRa	ZigBee	WiFi
Estándar	IEEE 802.15.1	LoRaWAN	IEEE 802.15.4	IEEE 802.11 a/c/b/d/g/n
Frecuencia	2.4 – 60 GHz	868/900 MHz	868/915 MHz 2.4 GHz	2.4 – 60 GHz
Tasa transf.	1 – 24 Mb/s	0.3 – 50 kb/s	40 – 250 kb/s	1 Mb/s – 6.75 Gb/s

Alcance	10 m	30 km	10-100 m	100m
---------	------	-------	----------	------

Bluetooth se descarta por su bajo rango de alcance y ZigBee por las limitaciones que presentó en la red del Apéndice I. LoRa también es descartada por presentar una tasa de transferencia más baja. Entre estas tecnologías, se selecciona WiFi por el rango y su capacidad de transferencia de datos.

5.5.3 Protocolo de la capa de aplicación

WiFi es una tecnología de comunicaciones que soporta el uso de diferentes protocolos a nivel de aplicación, por ello, estos protocolos deben ser evaluados antes de su selección. La tabla 3 del artículo del Apéndice III (similar a la Tabla 5.3) contiene la información más relevante de los protocolos evaluados. Entre ellos, se selecciona MQTT por tener un tamaño de cabecera pequeño y por su gran uso como protocolo en IoT.

Tabla 5.3: Comparativa de los principales protocolos de la capa de aplicación para IoT

Protocolo Especificación	MQTT	CoAP	AMQP	HTTP
Capa de transporte	TCP	UDP	TCP	TCP
Tamaño mínimo de la cabecera	2 Bytes	4 Bytes	8 Bytes	26 Bytes
Calidad del servicio (QoS)	3 niveles	2 niveles	2 niveles	limitado
M2M/Uso IoT	El mayor	Medio	Alto	Bajo

5.5.3.1 Tarjeta de desarrollo

El microcontrolador empleado para el desarrollo de esta red de sensores es el ESP32 de *Espressif Systems*. Se trata de un microcontrolador de 32 bits a 240 MHz con canales ADC de 12 bits, varias interfaces digitales y conectividad Wi-Fi y Bluetooth integradas.

Este microcontrolador, a pesar de ser un buen candidato presenta varios problemas, principalmente en el ruido y no linealidad del ADC integrado. Siguiendo las recomendaciones del fabricante, el ADC integrado no mejora lo

suficiente para el propósito de la red. Aunque el perfil de ruido podría ser aceptable para una medida puntual, es un problema considerable cuando múltiples señales son procesadas por algoritmos de estimación del CMV.

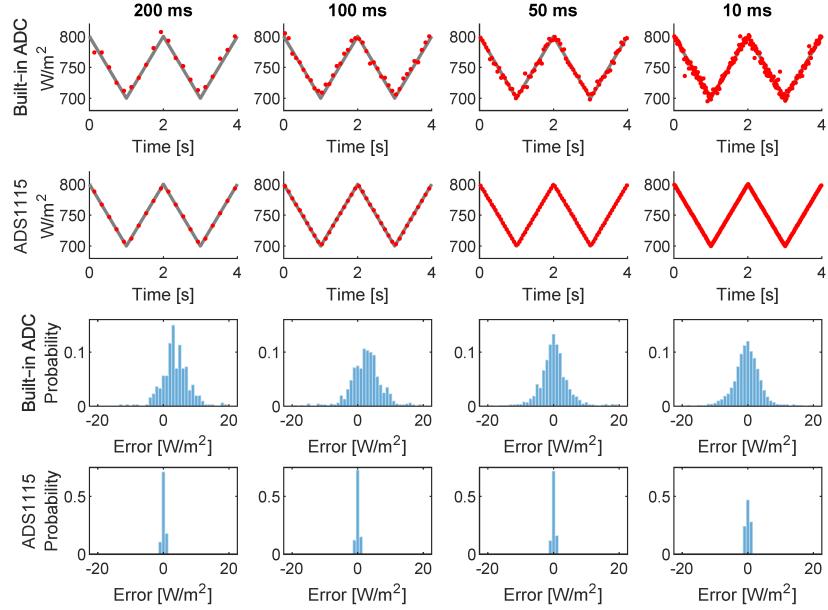


Figura 5.15: Comparativa del ADC a diferentes tasas de muestreo.

Por ello, se evalúa el ruido del ADC integrado del microcontrolador y un ADC externo que se comunica mediante el protocolo I^2C empleando para la comparativa una rampa equivalente a 100 W/m^2 en la zona lineal del ADC integrado. Estas pruebas quedan representadas en la Figura 5.15, donde cada columna representa el desempeño de los ADCs comparados para diferentes tasas de muestreo. El circuito integrado que hace la función de ADC externo es el ADS1115, que se trata de una opción económica con 16 bits de precisión y una velocidad de muestreo de hasta 860 muestras por segundo, lo que permite alcanzar tasas de muestreo muy superior a lo requerido. Por ello y debido a la reducción de ruido obtenida con el ADC externo, queda justificado el uso del mismo en el desarrollo de la red.

5.5.3.2 Selección del sensor

En el artículo presentado en el Apéndice I, se expone que el sensor de termopila usado (Piranómetro *Secondary-Standard CMP11* de Kipp & Zonen) tiene un tiempo de respuesta lento, y por tanto no es apropiado para capturar los eventos rápidos de irradiancia. Por ello, se opta por piranómetros basados en fotodiodos, en concreto el SP-214 de *Apogee Instruments, Inc.*, cuyas carac-

terísticas principales quedan recogidas en la Tabla 5.4.

Tabla 5.4: Especificaciones del piranómetro SP-214

Especificación	Valor
Rango de alimentación	7–24 V DC
Rango de salida	4–20 mA
Factor de calibración	125 W/m ² por mA + 4 mA offset
Sensibilidad	0.008 mA por W/m ²
Rango de medida	0–2000 W/m ²
No-linealidad	<1% (hasta 2000 W/m ²)
Tiempo de respuesta	<1 ms

5.5.3.3 Prototipo del nodo

El prototipo del nodo se construye mediante la conexión del ADC externo al ESP32. Una fuente de alimentación externa de 15 V DC alimenta al piranómetro y a un regulador de tensión tipo DC-DC para obtener 3.3 V, que a su vez alimenta al ESP32 y al ADC externo. La Figura 5.16 muestra las conexiones entre los diferentes componentes del nodo.

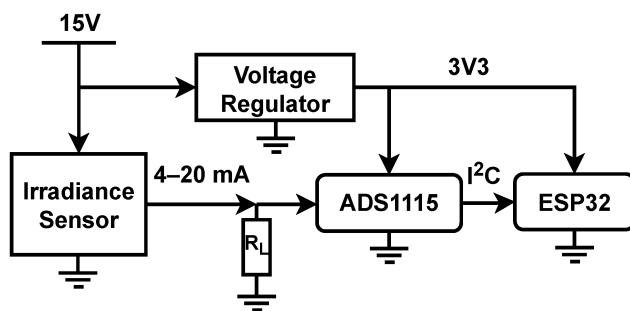


Figura 5.16: Diagrama electrónico del nodo de la red de sensores inalámbrica.

Todos estos componentes se colocan dentro de una caja, a excepción del sensor de irradiancia. El aspecto de la electrónica dentro de la caja y el prototipo del nodo se puede ver en las Figuras 5.17a y 5.17b.

Para la resistencia de carga, R_L , se emplea una resistencia de 150Ω , trasladando la salida de 4 – 20 mA del piranómetro a una tensión en el rango de 0.6 a 3 V.

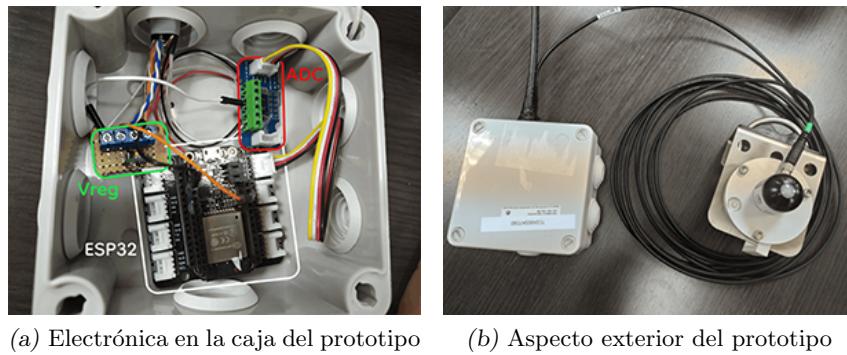


Figura 5.17: Electrónica y aspecto del prototipo

5.5.3.4 Resultados del campo de irradiancia

El objetivo final del diseño de esta red es poder capturar la evolución del campo de irradiancia. Esta red se despliega en la azotea del edificio de la Escuela Técnica Superior de Ingeniería de Algeciras en una configuración mallada de 4x4, cubriendo un área de $15 \times 15 m^2$, como se muestra en la Figura 5.18



Figura 5.18: Red de sensores WiFi desplegada en la azotea del edificio. Los círculos rojos indican la ubicación de los piranómetros, el círculo azul ubica la posición de las fuentes de alimentación y el router.

Las campañas de monitorización realizadas con este despliegue confirmaron la validez de esta red de sensores. Un fragmento de 60 segundos de una campaña de monitorización a 500 ms puede verse en la Figura 5.19 y la evolución del campo de irradiancia asociado a esta serie en la Figura 5.20.

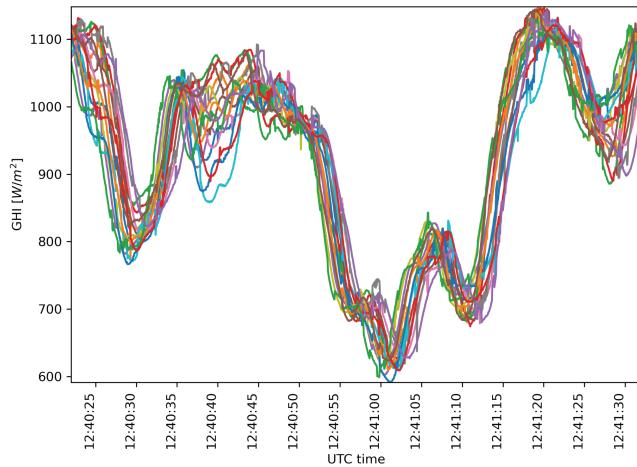


Figura 5.19: 60 s de 16 series temporales de irradiancia capturada por la red de sensores el 10 de Febrero de 2022.

5.6 Objetivo 6: Análisis y desarrollo de un sistema de adquisición para los datos de la red de sensores.

Este objetivo es un paso necesario para los artículos de los Apéndices I y III. En el primer caso se desarrolló inicialmente un sistema de control y adquisición en *MATLABTM*, aunque no se profundizó más debido a los múltiples problemas y limitaciones que presentaba la red de sensores. El coordinador mandaba por el puerto serie la información recibida de la red de sensores, y una interfaz de usuario desarrollada en este entorno enviaba comandos a los nodos y procesaba los datos de la red. Debido a las limitaciones que presentaba ya de por sí la red, se optó por el almacenamiento local.

Para la red de sensores desarrollada en el artículo del Apéndice III, se desarrollaron dos sistemas de adquisición como se describe en la subsección 2.6 de dicho artículo, a fin de someterlo a pruebas de rendimiento bajo diferentes períodos de muestreo. Ambos sistemas de adquisición emplean bases de datos diferentes y que suelen ser empleadas en sistemas similares. La topología de la red empleada en las pruebas de comparación se puede ver en la Figura 5.21. El flujo de datos en Node-RED se puede observar en la Figura 5.22.

Las pruebas de rendimiento mostraron rápidamente que la configuración Node-RED y MariaDB presentaba importantes cuellos de botella cuando la red de 16 sensores trabajaba con períodos de muestreo inferiores a 200 ms. Por ello, esta rama fue finalmente descartada para el análisis de las pruebas de rendimiento, resultando en la topología de red final mostrada en la Figura 5.23

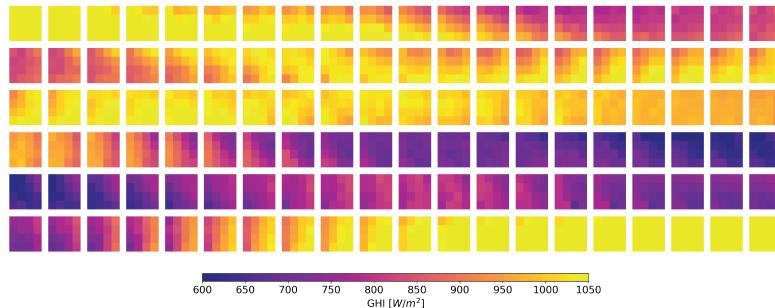


Figura 5.20: Evolución del campo de irradiancia a 500 ms de la serie temporal mostrada en la Figura 5.19. donde cada fila representa una duración de 10 segundos, y la diferencia entre dos columnas consecutivas de cada fila es de 500 ms.

5.7 Objetivo 7: Desarrollo de algoritmo para la estimación de la dirección y velocidad de la nube.

El artículo del Apéndice II analiza los métodos de estimación de movimiento de nube a partir de redes de sensores de irradiancia y propone un nuevo método. En este artículo se detallan los métodos más usados por la comunidad científica y se emplean dos de ellos como base de comparación para la propuesta del nuevo algoritmo.

Estimar el CMV desde una red de sensores no es tan trivial como con una cámara de cielo donde se dispone de millones de puntos de información. En el caso de la red de sensores nos encontramos con medidas puntuales y el objetivo de estimar el movimiento se convierte en el conocido ‘problema de apertura’. Este problema establece que el movimiento de un objeto como una barra o un borde no puede ser determinado inequívocamente si es visto a través de una pequeña apertura.

5.7.1 Consideraciones preliminares

El concepto del problema de apertura trasladado a redes de sensores se aclara en esta sección 2, “Consideraciones preliminares”, del artículo del Apéndice II:. En él se indica, que suponiendo una red de irradiancia con una estructura mallada de $n \times n$ sensores por la que pasa la sombra de una nube moviéndose a una velocidad $\vec{v} = (v_x, v_y)$ como se indica en la Figura 5.24a, la evolución que se vería en el campo de irradiancia inicial y un segundo después sería Figura 5.24b y Figura 5.24c. Como se puede observar, la evolución aparente no coincide con el CMV.

En esta misma sección se analiza las velocidades máximas detectables por una red de sensores teniendo en cuenta las dimensiones de la misma y la

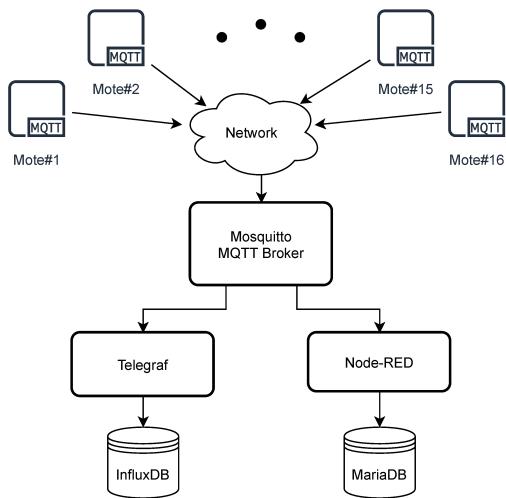


Figura 5.21: Topología de red empleada para la comparativa de los sistemas de adquisición. Los puntos representan el resto de nodos de la red.

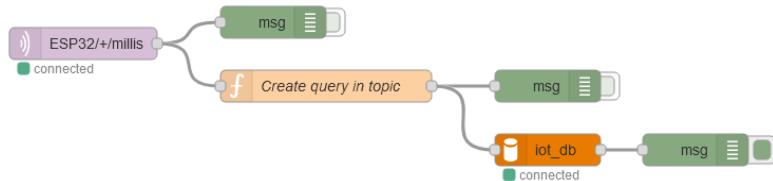


Figura 5.22: Flujo de datos implementado en Node-RED para el sistema de adquisición de MariaDB.

frecuencia de muestreo, siendo un límite superior de detección de la red.

Esta sección del artículo presenta también la necesidad de generación de datos sintéticos, ya que los datos reales siguen teniendo el inconveniente de que el CMV real se mantiene desconocido. Por ello, las validaciones que se realizan en este trabajo se hacen en un marco sintético para generar series temporales de irradiancia en función de un CMV conocido. Para generar estas series temporales de irradiancia sintéticas, se emplea el modelo de nube fractal descrito por Lohman en [66] para generar un campo de irradiancia de unos 8 x 8 km con una resolución de 1 m (Figura 5.25). Este campo de irradiancia se desplaza sobre el dominio de monitorización acorde al CMV, generando series de irradiancia en función del periodo de muestreo (ver dominios de la Figura 5.25), obteniéndose de esta forma instantáneas de la red de la red de sensores como se muestra en la Figura 5.25 S_t y S_{t+1s} .

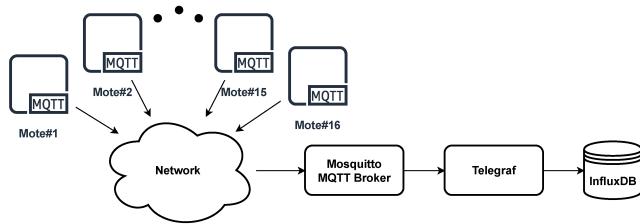
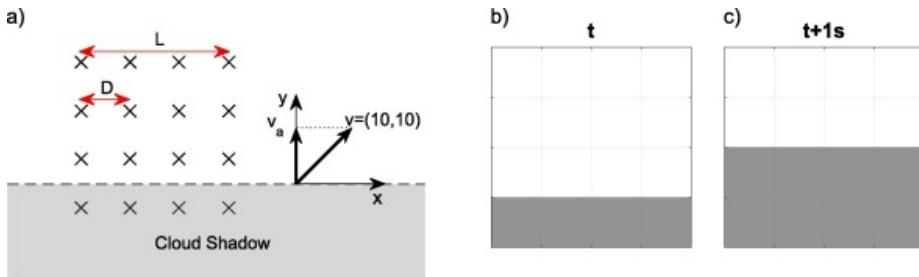


Figura 5.23: Topología de la red final.

Figura 5.24: a) Esquema de una red de sensores de 4×4 con una nube desplazándose en la dirección y velocidad indicada por el vector v . b) Campo de irradiancia en instante inicial t . c) Campo de irradiancia en el instante $t+1s$.

5.7.2 Modelos de referencia

La sección ‘Métodos de referencia’ del artículo del Apéndice II resume los dos métodos más conocidos para obtener el CMV con una red de irradiancia. Estos métodos se llaman “Par más correlacionado” (*Most Correlated Pair, MCP*) y “Borde de nube recto” (*Linear Cloud Edge, LCE*), que son la base de comparación para el método desarrollado en este artículo.

El primero de ellos, el MCP, se presenta por primera vez en [61] y asume que en una red de sensores, dos sensores presentarán cierto tiempo de retraso (t_{ab}) y una alta correlación entre ellos. La dirección de la nube se obtiene asumiendo como la posición de los sensores que muestran la mayor correlación y la velocidad se estima como distancia entre esos sensores dividido entre el tiempo de retraso que presentan sus series temporales.

El segundo método, denominado LCE, es presentado por primera vez por Bosch en [62], precisa de 3 sensores, y mediante relaciones trigonométricas se estima el CMV. Ambos métodos se encuentran brevemente detallados en la Sección 4.3.6.2 de esta tesis.

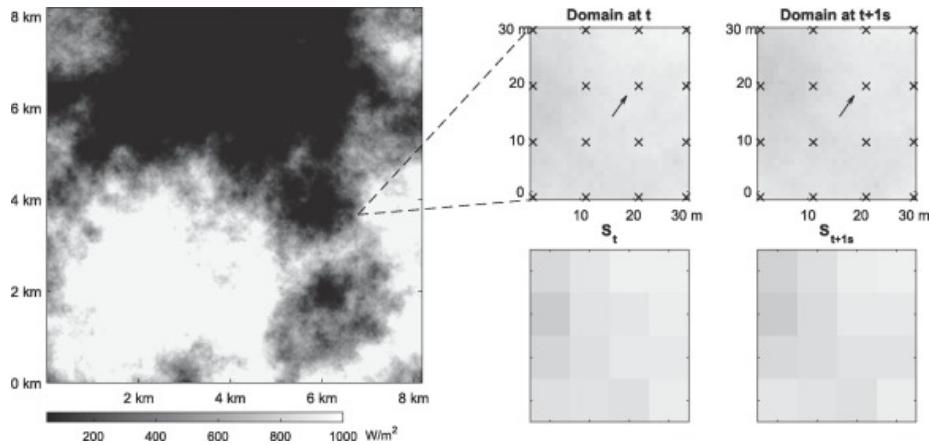


Figura 5.25: Generación de instantáneas de la red de monitorización mediante el modelo de nube fractal. Las gráficas superiores de la derecha muestran la evolución del área monitorizada dado el CMV representado en el centro de las gráficas. La posición de los sensores está indicado mediante una 'x'. Las gráficas inferiores de la derecha muestran las instantáneas que se obtendría por la red de sensores.

5.7.3 Propuesta de un nuevo método

Esta sección 4 del artículo del Apéndice II, “Propuesta de un nuevo método”, discute la validez del método de correlación cruzada (*Cross Correlation Method, CCM*) para redes de sensores. Este método está basado en encontrar partes de una imagen anterior en la siguiente para estimar desplazamientos. Los desplazamientos observados y la diferencia temporal entre ambas imágenes son usadas para estimar el CMV. El coeficiente de correlación cruzada da una medida de similaridad entre la parte buscada y una porción de la imagen actualizada mediante convolución de sus correspondientes valores.

Este método funciona bien en imágenes de cielo completo e imágenes de satélite, donde la cantidad de puntos de información es considerable (del orden de millones de puntos). Para redes de sensores, donde la cantidad de puntos de información no es tan abundante y el área monitorizada es más limitada, se pueden realizar modificaciones del CCM para poder aplicar el método.

Una de las modificaciones necesarias sobre el CCM es ampliar la búsqueda del desplazamiento a toda la instantánea, usando toda la información como plantilla de referencia. Otra modificación consiste en permitir cruzar los límites de la imagen para encontrar estas coincidencias en la siguiente instantánea. Con estas modificaciones y considerando instantáneas de $n \times n$ puntos de información, $2n-1$ desplazamientos son posibles en cada eje.

La Figura 5.26 muestra cuatro ejemplos didácticos de dos instantáneas consecutivas considerando una red de sensores de 4×4 , e imponiendo el mis-

mo CMV, indicado por la flecha roja de cada figura ($V_x = 2D, V_y = 1D$). La columna marcada con r , corresponde al coeficiente de correlación cruzada para cada caso presentado. El cálculo de este coeficiente se puede definir por la Ecuación 5.2.

$$r = \sum_{k=1}^N S'_t(k) \cdot S'_{t+T_s}(k) \quad (5.2)$$

Donde S'_{t+T_s} denota las submatrices solapadas de las instantáneas de la red de sensores S_t y S_{t+T_s} para un determinado desplazamiento $\Delta x \Delta y$. N hace referencia al número de elementos (puntos de información) solapados y k un índice genérico que abarca estos elementos. Es importante tener en cuenta que los desplazamientos reducen el número de puntos solapados sobre los que el coeficiente se computa, que va desde n^2 elementos para desplazamiento nulo, hasta un elemento para el máximo desplazamiento en ambos ejes. Esto muestra el primer problema con la modificación de CCM, los valores obtenidos están sesgados debido al diferente número de elementos solapados, y consecuentemente, diferentes elementos involucrados en la convolución. Este sesgo se puede observar en la columna r de la Figura 5.26, donde independientemente de los rasgos, el mayor valor del coeficiente r está asociado a un desplazamiento de $\Delta x = 0, \Delta y = 0$ y los más bajos están asociados con los máximos desplazamientos (las esquinas del diagrama).

Para superar este problema, el coeficiente r puede ser dividido entre el número de elementos involucrados en la convolución (número de puntos solapados), esto resulta en nuevo coeficiente que termina siendo llamado “coeficiente de correlación cruzada normalizado”, \bar{r} , y que puede ser definido por la Ecuación 5.3. Los resultados incluyendo esta corrección son mostrados en la columna \bar{r} de la Figura 5.26. Se puede apreciar que los efectos de bordes han desaparecido en estos diagramas, pero el coeficiente parece no ser apropiado para la detección del movimiento de la nube, que solo es claramente visible en la gráfica superior (caso a). A pesar de que el desplazamiento de la nube entre instantáneas parece evidente, el valor más alto de \bar{r} está asociado a otros desplazamientos. La razón es que estos valores son obtenidos en desplazamientos en los que el punto asociado con el valor más bajo de irradiancia es excluido (fuera del área de solapamiento), y por tanto, la convolución se realiza solo con los valores máximos.

$$\bar{r} = \frac{1}{N} \sum_{k=1}^N S'_t(k) \cdot S'_{t+T_s}(k) \quad (5.3)$$

Se puede mejorar este último resultado restando la media de la instantánea, de este modo, se introducen valores positivos y negativos en la convolución. Este coeficiente de correlación modificado, r' , puede ser interpretado como un coeficiente de correlación cruzada normalizado con media cero, y se define por la

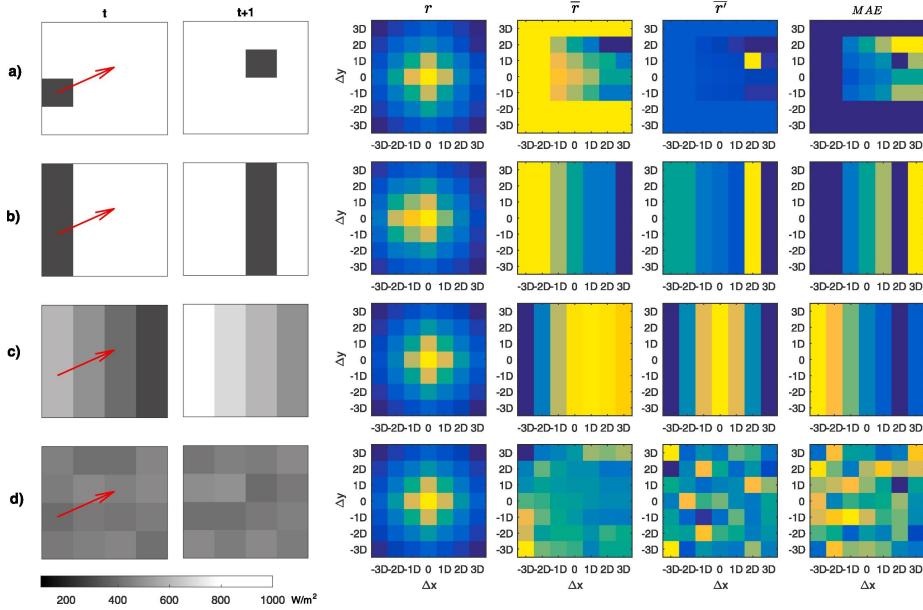


Figura 5.26: Las dos primeras columnas representan instantáneas de irradiancia en el tiempo t y $t+1$ en cuatro situaciones teóricas con un CMV común ($\text{CMV}=(2\text{D},1\text{D})$), representado por la flecha roja. El resto de columnas muestra los diagramas de desplazamiento obtenidos con los coeficientes de similitud mostrados en la parte superior de la columna. La mejor coincidencia de desplazamiento está asociado con el mayor valor de r , \bar{r} y \bar{r}' , y con el valor más bajo del MAE (Mean Absolute Error)

Ecuación 5.4. Estos resultados se muestran en la respectiva columna de la Figura 5.26. En el caso a), este nuevo coeficiente asigna inequívocamente el máximo valor \bar{r}' al desplazamiento $\Delta x \Delta y = (2D, 1D)$, que coincide con el CMV. En el caso b), se obtiene como salida una banda de valor máximo, que representa todos los desplazamiento con un $\Delta x = 2D$, en el que todos los Δy son igual de probables según el coeficiente. Este método no es capaz de ofrecer información útil para los casos c) y d) que son los más realistas.

$$\bar{r} = \frac{1}{N} \sum_{k=1}^N (S'_t(k) - \bar{S'}_t) \cdot (S'_{t+T_s}(k) - \bar{S'}_{t+T_s}) \quad (5.4)$$

Los coeficientes de correlación cruzada normalizada y coeficiente de correlación cruzada con media cero son ampliamente usados en aplicaciones de visión por ordenador [67].

5.7.4 El método del error medio absoluto acumulado

En esta sección se desarrolla y detalla la implementación el nuevo algoritmo propuesto en el artículo del Apéndice II. En primer lugar, se propone la sustitución de la convolución por el error medio absoluto, Ecuación 5.5, como medida de similitud.

$$MAE = \frac{1}{N} \sum_{k=1}^N |S'_t(k) - S'_{t+T_s}(k)| \quad (5.5)$$

Consecuentemente, la búsqueda del máximo coeficiente de correlación cruzada puede ser reemplazado por la búsqueda del mínimo MAE. La columna indicada con ‘MAE’ de la Figura 5.26 muestra los diagramas obtenidos con esta modificación. En el caso a), el diagrama muestra un valor mínimo para todos aquellos desplazamientos que excluyen los elementos con los valores más bajo de irradiancia. Este efecto es análogo al observado por el coeficiente \bar{r} , pero a diferencia de este, MAE también asigna un valor mínimo al desplazamiento real $\Delta x = 2D, \Delta y = 1D$. En caso b) el valor mínimo del MAE está asociado con el desplazamiento en el cual la banda de baja irradiancia es excluida, pero también con los desplazamientos con $\Delta x = 2D$, acorde con la velocidad aparente real. En estos dos primeros casos simplificados, el MAE como coeficiente es un mejor indicador que \bar{r} aunque no mejora \bar{r}' que inequívocamente determina el desplazamiento o banda de desplazamiento compatible con el movimiento capturado en las instantáneas.

El MAE muestra sus beneficios en los casos más realistas c) y d) en los cuales ni \bar{r} ni \bar{r}' ofrecen información útil. En el caso de c), el diagrama de MAE muestra una banda de valores mínimos en $\Delta x = 2D$, que indica una familia de desplazamientos que son compatibles con la velocidad aparente. En el caso ruidoso d), el valor mínimo del MAE indica claramente el desplazamiento real. Teniendo en cuenta que las instantáneas reales de irradiancia son una mezcla entre c) y d), el MAE ofrece una mejor medida de similitud en este contexto.

El MAE por sí solo no resuelve los problemas de ambigüedad de la velocidad aparente. Sin embargo, la acumulación de diagramas MAE en diferentes instantes de tiempo ofrece una solución gráfica a este problema, como se muestra didácticamente en la Figura 5.27. Las instantáneas muestran 3 frentes de nubes con un mismo CMV, en el que el movimiento detectado parece estar condicionado con la orientación del borde de la nube. El diagrama CMAE muestra como la acumulación de diagramas MAE de diferentes bordes de nubes determina inequívocamente el desplazamiento común. Este método permite agregar múltiples eventos, no solo bordes de nube.

La Figura 5.28 muestra la evolución del diagrama CMAE durante 300 segundos empleando para ello dos secuencias diferentes generadas con nubes fractales. En ambos casos, las primeras evoluciones ofrecen información de desplazamiento de las nubes de forma ambigua debido a la falta de agregación de

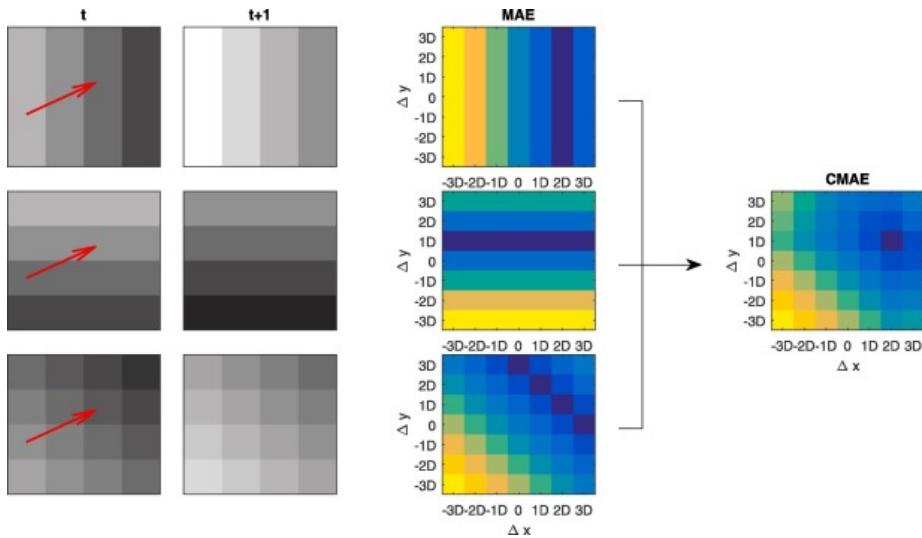


Figura 5.27: Instantáneas de irradiancia en el tiempo t y $t+1$ en tres situaciones teóricas con un $CMV = (2D, 1D)$ común y sus correspondientes diagramas MAE. El gráfico de la derecha representa el diagrama MAE acumulado (*Cumulative Mean Absolute Error, CMAE*), obtenido por la agregación de los 3 diagramas MAE.

diagramas MAE. Después de algunas agregaciones los diagramas comienzan a mostrar claramente los desplazamientos que mejor explican las variaciones de irradiancia durante todo el periodo (los valores más bajos del diagrama CMAE).

Cuando el diagrama CMAE muestra una zona de bajo MAE, se ha encontrado que la mejor estimación del CMV es mediante una interpolación ponderada inversa de los 3 desplazamientos con el valor del CMAE más bajo según las Ecuaciones 5.6 y 5.7

$$(V_x, V_y) = \frac{1}{T_s} \sum_{i=1}^3 w_i \cdot (\Delta_i x, \Delta_i y) \quad (5.6)$$

$$w_i = \frac{\frac{1}{CMAE_i}}{\sum_{j=1}^3 \frac{1}{CMAE_j}} \quad (5.7)$$

donde i y j son índices que recorren los 3 desplazamientos con los valores más bajos de CMAE, w_i representa la contribución del desplazamiento i -ésimo al CMV, y $CMAE_i$ el error agregado del desplazamiento i -ésimo.

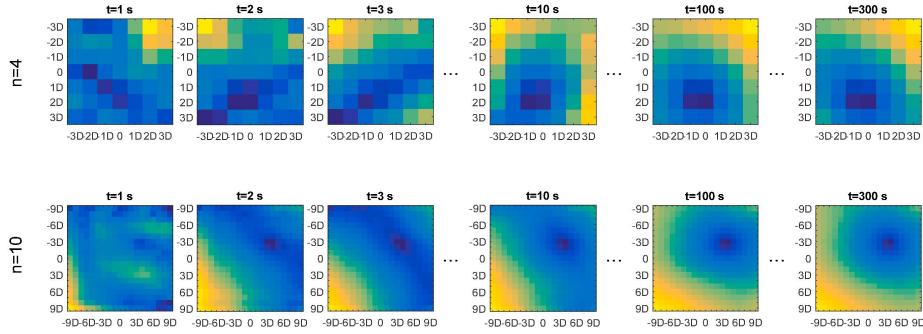


Figura 5.28: Evolución de los diagramas CMAE durante 300 s. La fila superior está asociado a una red 4×4 con $D = 10$ m, $T_s = 1$ y un CMV de entrada de $(-5, -17)$ m/s. El método estima un CMV $= (-6.28, -17.11)$ m/s. La fila inferior está asociado con una red de 10×10 con $D = 3.3$ m y $T_s = 1$, con un CMV de entrada de $(12, 9)$ m/s, estimando el método un CMV de $(12.18, 8.99)$ m/s.

5.7.5 Resultados

Para evaluar la habilidad de estimación del algoritmo desarrollado se realizan diferentes pruebas considerando configuraciones de red variando el número de sensores, tamaño de área monitorizada y períodos de muestreo. Concretamente se ensayan configuraciones con 9 ($n=3$), 16 ($n=4$), 36 ($n=6$) y 100 ($n=10$) sensores con longitudes de lado de 10, 30, 50 y 100 m. Con cada configuración, se generan 100 CMV aleatorios con velocidades comprendidas entre 0 y 30 m/s y direcciones desde 0 a 360° , que se aplican a la nube fractal generada, para crear secuencias de irradiancia sintética en cada sensor de la red con 300 s de duración. A cada secuencia se le aplican tres métodos de estimación del CMV: MCP, LCE y CMAE.

Las primeras pruebas con estas configuraciones se realizan con un periodo de muestreo de 1 s para probar los métodos con diferentes configuraciones de red. Los resultados de estimaciones de velocidades son presentados en la Figura 5.29, y de direcciones en la Figura 5.30. La primera conclusión general es que el método del LCE muestra el peor rendimiento en todos los casos, con la excepción de $n = 3$ y $L = 100$ m, en el cual todos los métodos son afectados seriamente por la baja densidad de puntos de medida. Los métodos MCP y CMAE muestran resultados comparables en la estimación de la dirección de la nube, aunque el CMAE estima mejor en grandes áreas ($L = 100$ m).

En la Figura 5.29 se observa un límite superior de velocidad en gráficas asociadas con $L = 10$ m que está asociado con la configuración de la red y el periodo de muestreo empleado. Con un periodo de muestreo de 1 s y con una longitud de lado de 10 m, se presenta una velocidad máxima de detección de $10 \cdot \sqrt{2}$ m/s, y que se da en la dirección diagonal de la red. El resto de

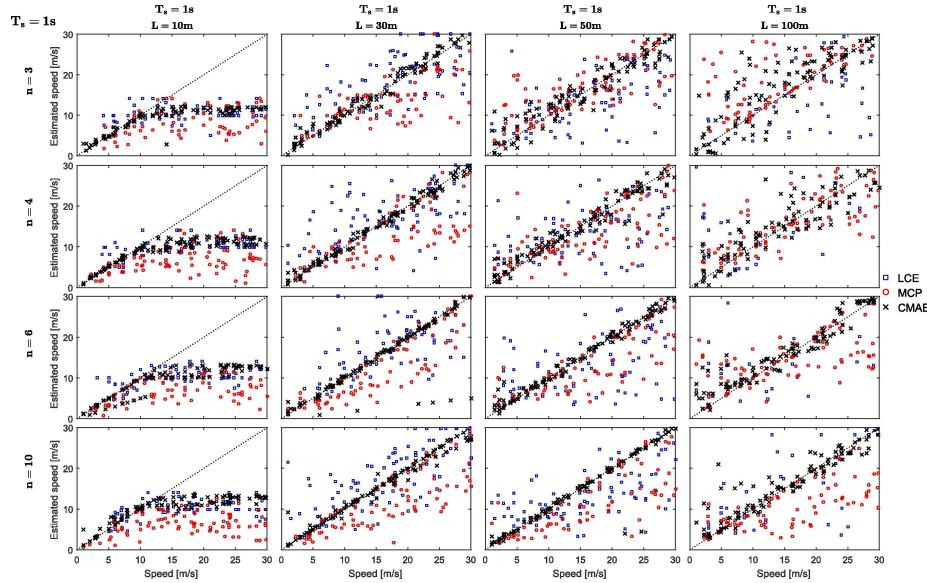


Figura 5.29: Resultados de velocidad para diferentes configuraciones con $T_s = 1s$.

configuraciones probadas no presentan esta limitación en las pruebas realizadas.

De modo general, el método del CMAE muestra el mejor rendimiento para todos los casos, especialmente en redes con alta densidad espacial de sensores. CMAE alcanza un error cuadrático medio (RMSE) de 1.4 m/s para la configuración $n = 10$ y $L = 30$, mientras que con esta configuración MCP y LCE obtienen un RMSE de 6.5 m/s y 5.6 m/s respectivamente. Para la configuración $n = 6$ y $L = 50$ m, los métodos CMAE, LCE y MCP obtienen unos valores de RMSE de 1.2 m/s, 6.2 m/s y 8.3 m/s respectivamente. Para otras comparativas incluyendo otros estadísticos, se sugiere consultar el Apéndice A del artículo.

Otras pruebas realizadas usan las mismas configuraciones adaptando el periodo de muestreo para detectar una velocidad máxima de 30 m/s. El periodo de muestreo empleado se encuentra indicado en la parte superior de cada gráfico de la Figura 5.31. Los gráficos de dirección se omiten debido a que no ofrecen información adicional respecto a la Figura 5.30. Los resultados de esta prueba están alineados con los anteriores, mostrando el método del CMAE una mejor estimación del CMV que los métodos del LCE y MCP. Los estadísticos asociados a esta prueba pueden ser consultados en el artículo del Apéndice II.

5.7.6 Generalización para redes no malladas

Una distribución regular de sensores no siempre es posible debido a que la configuración de la red está frecuentemente limitada por la presencia de obstáculos y la infraestructura existente en el área de interés. Debido a que las distribu-

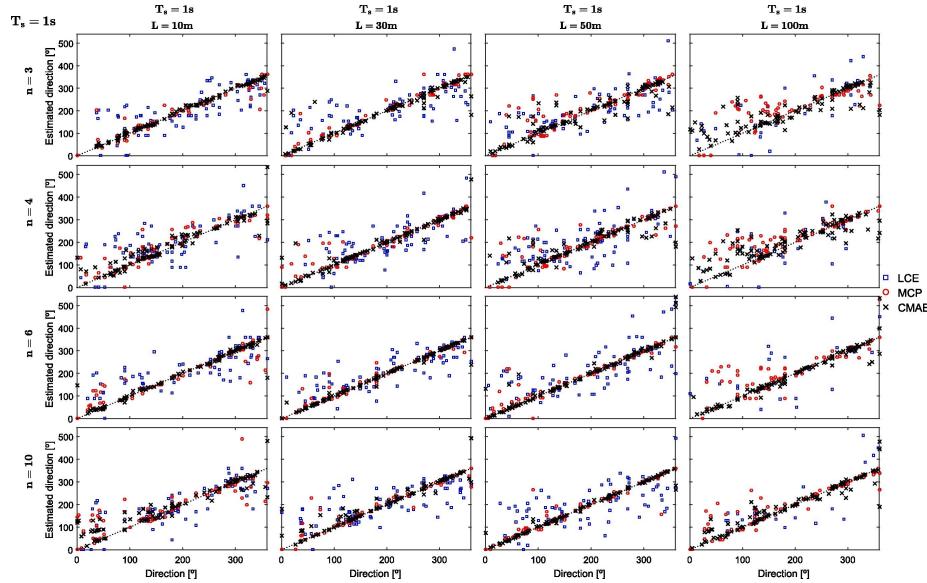


Figura 5.30: Resultados de dirección para diferentes configuraciones con $T_s = 1s$.

ciones no malladas no ofrecen instantáneas regulares que permitan la aplicación directa del método del CMAE, este podría tener limitación en la aplicación de casos reales. En este sentido, el método de kriging de inferencia espacial podría ser usado para generar valores de irradiancia mallados en ubicaciones no observadas a partir de un conjunto de observaciones no malladas [68] [69]. El método del CMAE puede ser aplicado a las instantáneas de irradiancia regulares obtenidas de esta forma.

Para mostrar la validez de esta técnica se generan instantáneas mediante kriging ordinario con variograma esférico como se describe en [70], el cual es una simple y común implementación de este método. Para ello se usan redes distribuidas aleatoriamente (no uniformemente) cubriendo el mismo área que la configuración mallada. Se generan series de irradiancia simulada de 30 segundos del mismo modo que se generó anteriormente. Las Figuras 5.32 y 5.33 muestra la comparativa de velocidad y dirección para configuraciones de $N=6$ y periodo de muestreo adaptado para ser capaz de estimar velocidades de 30 m/s. Las estimaciones de dirección tienen un rendimiento similar, siendo precisas en pequeñas áreas (frecuencia de muestreo alta) y una dispersión mayor en áreas más grandes (frecuencia de muestreo más baja). Sin embargo, los valores de velocidad en la configuración no mallada muestra un sesgo, resultando en una estimación mayor, proporcional a la velocidad empleada y afectada por el tamaño del área monitorizada. Se puede afirmar que la incertidumbre introducida por la interpolación se traslada a las estimaciones de velocidad.

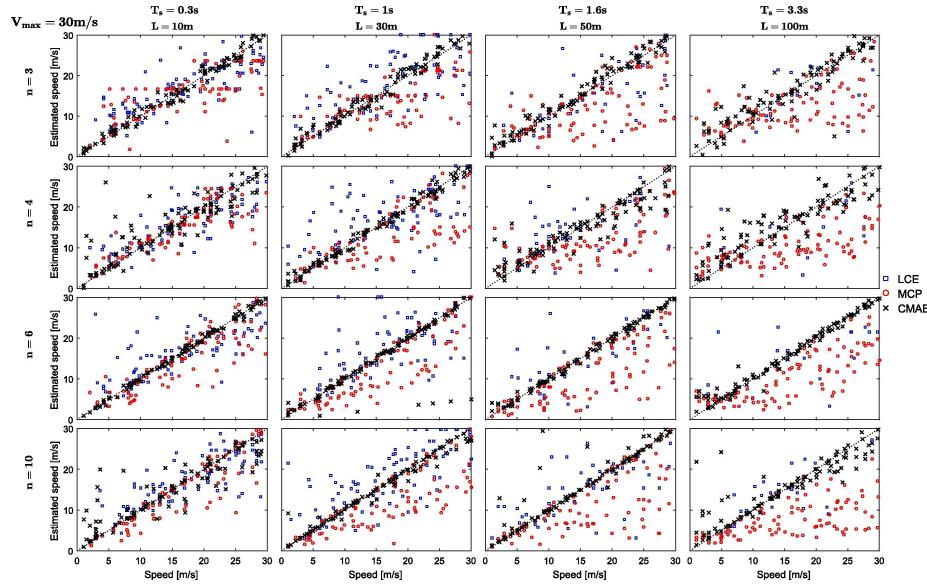


Figura 5.31: Resultados de velocidad para diferentes configuraciones considerando $V_{max} = 30m/ss$.

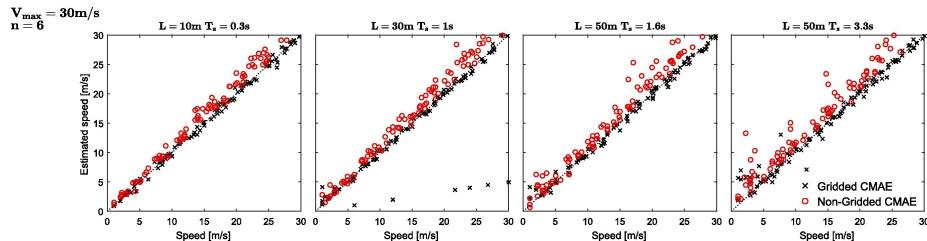


Figura 5.32: Comparación de velocidad para redes de sensores malladas y no malladas.

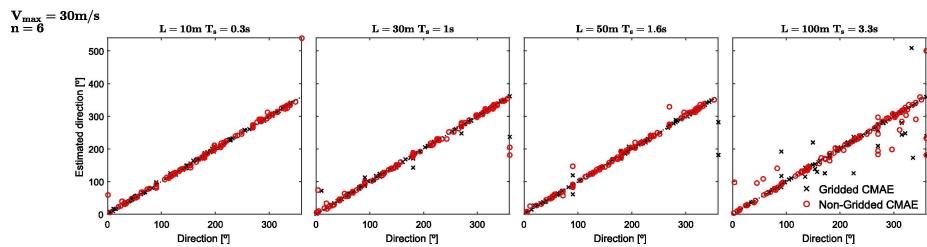


Figura 5.33: Comparación de dirección para redes de sensores malladas y no malladas.

CAPÍTULO 6

Conclusiones

Los resultados obtenidos en esta tesis doctoral dedicada al estudio y desarrollo de redes de sensores para la predicción a corto plazo ha permitido alcanzar las siguientes conclusiones principales.

6.1 Resumen de las conclusiones más relevantes

1. Es posible estimar el CMV a partir de la información obtenida de una red de sensores de irradiancia (Apéndice II).
 - a. Los algoritmos que emplean pocos sensores, como el método del LCE (*Linear Cloud Edge*) que solo necesita 3 sensores, parece ofrecer estimaciones de CMV con mayor incertidumbre que los métodos que usan más sensores, como el MCP (*Most Correlated Pair*)
 - b. El algoritmo desarrollado en el artículo del Apéndice II denominado CMAE, utiliza todos los sensores de la red para la estimación del CMV, ofreciendo estimaciones con poca incertidumbre.
2. La velocidad máxima detectable por una red de sensores se ve influenciada por el área cubierta y la tasa de muestreo empleada (Apéndice II).
 - a. La velocidad máxima detectable por una red de sensores depende del área cubierta y de la tasa de muestreo de la red, con poca dependencia de la cantidad de sensores en la red. La Figura 7 del artículo del Apéndice II muestra un límite superior detectable en torno a 12 m/s para un área de $10 \times 10 \text{ m}^2$ con un periodo de muestreo de 1 s, esta prueba se realiza con 9, 16, 36 y 100 sensores, mostrando todas un límite similar.
 - b. La precisión de las estimaciones es proporcional a la densidad espacial de nodos. En la Figura 7 del artículo del Apéndice II se aprecia como configuraciones con baja densidad espacial (9 y 16 sensores cubriendo

100x100 m) ofrecen estimaciones menos precisas que configuraciones más densamente monitorizadas.

3. El algoritmo desarrollado para estimación de CMV, CMAE, puede ser empleado con redes de sensores distribuidas de forma irregular (Apéndice II).
 - a. El método del CMAE fue ideado para redes distribuidas de forma de matriz regular, aunque se ha demostrado que no está limitado esta distribución. Es posible emplear este método en redes con distribución espacial irregular si se aplican métodos de inferencia espacial como kriging. Las Figuras 5.32 y 5.33 muestran las comparaciones de las estimaciones de velocidad y dirección usando una red distribuida regularmente y una red distribuida de forma aleatoria. La red irregular parece estimar la velocidad con algo más de incertidumbre respecto a la red regular y con cierto sesgo al alza. En cambio, los resultados en dirección son similares.
4. Los luxómetros pueden ser una alternativa económica a los piranómetros en redes de sensores de irradiancia (Apéndice I).
 - a. Los luxómetros presentaron una excelente correlación con el piranómetro de referencia usado, aunque cada luxómetro se tuvo que calibrar de forma individual. La causa de esta particularidad puede ser debida al proceso de fabricación y/o a las tolerancias de los componentes empleados en los prototipos desarrollados.
 - b. Los sensores de iluminación presentaron un tiempo de respuesta muy inferior al piranómetro de referencia empleado, lo que en cierta medida es una ventaja para la detección de eventos rápidos de irradiancia. Mientras los luxómetros desarrollados, basado en el sensor SFH5711 de OSRAM presentaba un tiempo de respuesta inferior a 1 ms, el piranómetro de calibración (CMP11 de Kipp & Zonen) presenta un tiempo de respuesta del orden de varios segundos.
 - c. Los luxómetros son una alternativa muy económica para el desarrollo de redes de sensores. Mientras los piranómetros tienen precios que van desde los pocos de cientos de euros hasta miles de euros según el patrón de referencia empleado, el sensor de iluminación empleado en el artículo del Apéndice I (SFH 5711 de OSRAM) no supera un par de euros la unidad.
 - d. Se encontró una excelente correlación entre el piranómetro de referencia y los luxómetros, con un índice de correlación comprendido entre 0.975 y 0.991. Este coeficiente de correlación es conservador, puesto que incluye eventos rápidos de irradiancia que el luxómetro es capaz de captar pero no el piranómetro de termopila empleado. Existe una correlación prácticamente lineal en el rango de 200 – 1000

W/m^2 , a partir de $1000 W/m^2$ esta linealidad se pierde, ya que valores superiores suelen estar asociados a eventos rápidos como el *Cloud-Enhancement*, y la diferencia debido a los tiempos de respuesta es más notoria.

- e. Para la calibración de los luxómetros, sería más apropiado emplear un piranómetro fotodiodo como referencia, por su tiempo de respuesta más rápido.
5. Es posible diseñar una red de sensores inalámbrica que ofrezca información de valor a los sistemas de predicción de irradiancia a corto plazo.
 - a. La red del Apéndice I se desarrolló con ZigBee, una tecnología que parecía prometedora según las especificaciones teóricas, en un despliegue real presentó numerosas limitaciones que no la hacían deseable para una red de monitorización en tiempo real. Entre estas limitaciones cabe destacar el límite de 2 muestras por segundo para 16 dispositivos, la falta de sincronía y desconexiones. A pesar de que la red no cumplía con los requisitos para su propósito, terminó siendo útil para la comparativa de luxómetros y piranómetros.
 - b. La red de sensores inalámbrica desarrollada en el artículo del Apéndice III emplea Wifi como tecnología de comunicaciones y supera incluso los requisitos más exigentes de redes de irradiancia cableadas consideradas a la vanguardia. La red ha sido probada con un muestreo de hasta 10 ms y con las medidas sincronizadas mediante servidor de tiempo de red, con incertidumbre inferior a 1 ms.
 - c. Las redes inalámbricas pueden ser una alternativa económica para desarrollar redes de monitorización de irradiancia sin la pérdida de ninguna prestación respecto a redes cableadas. La característica inalámbrica permite la instalación y movilidad de los nodos con mayor facilidad que una red de sensores cableada, a la vez que permite añadir nuevos nodos a la red sin costes significativos.
6. El sistema de adquisición de datos para la red de sensores debe ser apto para la tasa de datos a gestionar y coherente con la finalidad de los datos (Apéndice III).
 - a. El sistema de adquisición, procesamiento y almacenamiento de datos debe ser capaz de gestionar el volumen de información esperado de la red. El artículo del Apéndice III se encontró limitaciones de procesamiento en uno de los sistemas de adquisición probados cuando se empleaban frecuencias de muestreo rápidas con 16 sensores. Esta limitación depende de la cantidad de información por segundo que debe ser procesada, por tanto, depende de la frecuencia de muestreo, de la cantidad de dispositivos y del tamaño de paquete a procesar.
7. Las redes de sensores tienen un gran potencial para formar redes de sensores colaborativas.

- a. Si pequeñas redes de sensores desplegadas sobre edificios alimentaran con sus datos a un sistema colaborativo, este podría usar la información de cada uno de ellos para obtener mapas de irradiancia empleando la información de toda la red y computar con mejor precisión el CMV.
- b. Cada una de estas redes colaborativas podrían beneficiarse del sistema global si este ofreciera el CMV calculado y el mapa de irradiancia de los alrededores de la red de sensores en cuestión.

CAPÍTULO 7

Perspectivas futuras

Los resultados obtenidos y conclusiones de esta Tesis Doctoral sirven para enfocar las perspectivas de trabajos futuros.

El subproyecto PID2019-108953RB-C21: “Energy and Meteorological Operational Data for photovoltaic plants (EMOD)” a cargo de miembros del grupo PAIDI-TIC-168 de la Universidad de Cádiz en el que participo, tiene por objetivos la generación de datos operaciones meteorológicos, de producción energética y la calidad eléctrica para sistemas fotovoltaicos.

Para ello, se despliegan redes de sensores de irradiancia en dos plantas solares que colaboran con el presente proyecto de investigación y localizadas en Córdoba. En ambas plantas se monitoriza de información de producción total y desagregada por cada inversor y por cada serie de paneles conectados entre sí (*strings*). De este modo, se puede analizar con mayor detalle como se transforma el campo de irradiancia en potencia instantánea. Adicionalmente, a las plantas fotovoltaicas se les han instalado equipos para el estudio y monitorización de la calidad de la energía generada. Con el conjunto de datos se pueden modelar las posibles perturbaciones en la calidad del suministro cuando ocurren cambios rápidos de irradiancia.

Otro objetivo del proyecto es el desarrollo de un sistema que ofrezca datos operacionales a plantas fotovoltaicas que sean de utilidad para la gestión de las mismas. El algoritmo de estimación de CMV ha mostrado buenos resultados con la red de sensores desplegada en la azotea del edificio de la Escuela Técnica Superior de Ingeniería de Algeciras. Por ello, uno de los primeros pasos será implementar el algoritmo desarrollado para estimar el CMV del artículo del Apéndice II con los datos de irradiancia de las plantas FV monitorizadas. Disponiendo del CMV y de una estimación del campo de irradiancia se desarrollarán e implementarán algoritmos de predicción de producción y calidad del suministro eléctrico.

CAPÍTULO 8

Bibliografía

- [1] “Paris agreement,” December 2015.
- [2] K. Protocol, “United nations framework convention on climate change,” *Kyoto Protocol, Kyoto*, vol. 19, no. 8, pp. 1–21, 1997.
- [3] D. Yang, W. Wang, C. A. Gueymard, T. Hong, J. Kleissl, J. Huang, M. J. Perez, R. Perez, J. M. Bright, X. Xia, D. van der Meer, and I. M. Peters, “A review of solar forecasting, its dependence on atmospheric sciences and implications for grid integration: Towards carbon neutrality,” *Renewable and Sustainable Energy Reviews*, vol. 161, p. 112348, 2022.
- [4] IRENA (2018), “Global energy transformation: A roadmap to 2050.”
- [5] G. Masson, A. Detollenaire, I. Kaizuka, A. Jäger-Waldau, and J. Donoso, *Snapshot of Global PV Markets 2021 Task 1 Strategic PV Analysis and Outreach PVPS*. IEA, 04 2021.
- [6] G. Masson and I. Kaizuka, “Trends in pv applications 2021– ieapvps,” 2021.
- [7] IEA, “Evolution of solar pv module cost by data source, 1970-2020.”
- [8] B. Zeqiang, L. Wenhua, S. Yizhuo, H. Xiaolei, and C. Wei, “Research on performance test method of silicon pyranometer,” in *2013 IEEE 11th International Conference on Electronic Measurement & Instruments*, vol. 1, pp. 43–48, 2013.
- [9] G. D. Rodriguez, “A utility perspective of the role of energy storage in the smart grid,” in *IEEE PES General Meeting*, pp. 1–2, 2010.
- [10] A. D. Mills and R. H. Wiser, “Implications of geographic diversity for short-term variability and predictability of solar power,” in *2011 IEEE Power and Energy Society General Meeting*, pp. 1–9, 2011.
- [11] T. E. Hoff and R. Perez, “Modeling pv fleet output variability,” *Solar Energy*, vol. 86, no. 8, pp. 2177–2189, 2012. Progress in Solar Energy 3.

-
- [12] J. Antonanzas, D. Pozo-Vázquez, L. Fernandez-Jimenez, and F. M. de Pison, “The value of day-ahead forecasting for photovoltaics in the spanish electricity market,” *Solar Energy*, vol. 158, pp. 140–146, 2017.
 - [13] K. Oureilidis, K.-N. Malamaki, K. Gallos, A. Tsitsimelis, C. Dikaiakos, S. Gkavanoudis, M. Cvetkovic, J. M. Mauricio, J. M. Maza Ortega, J. L. M. Ramos, G. Papaioannou, and C. Demoulias, “Ancillary services market design in distribution networks: Review and identification of barriers,” *Energies*, vol. 13, no. 4, 2020.
 - [14] Sinergise Ltd, “Eo browser.”
 - [15] M. Lave, J. Kleissl, and E. Arias-Castro, “High-frequency irradiance fluctuations and geographic smoothing,” *Solar Energy*, vol. 86, no. 8, pp. 2190–2199, 2012. Progress in Solar Energy 3.
 - [16] R. Karandeh, W. Prendergast, and V. Cecchi, “Optimal scheduling of battery energy storage systems for solar power smoothing,” in *2019 Southeast-Con*, pp. 1–6, 2019.
 - [17] Y. Hida, Y. Miyaguchi, R. Yokoyama, and K. Iba, “A study of optimal capacity of bess to mitigate unstable of solar power generation,” in *2010 Modern Electric Power Systems*, pp. 1–5, 2010.
 - [18] S. Shivashankar, S. Mekhilef, H. Mokhlis, and M. Karimi, “Mitigating methods of power fluctuation of photovoltaic (pv) sources – a review,” *Renewable and Sustainable Energy Reviews*, vol. 59, pp. 1170–1184, 2016.
 - [19] R. Hemmati, H. Mehrjerdi, and M. Bornapour, “Hybrid hydrogen-battery storage to smooth solar energy volatility and energy arbitrage considering uncertain electrical-thermal loads,” *Renewable Energy*, vol. 154, pp. 1180–1187, 2020.
 - [20] X. Chen, Y. Du, W. Xiao, and S. Lu, “Power ramp-rate control based on power forecasting for pv grid-tied systems with minimum energy storage,” in *IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society*, pp. 2647–2652, 2017.
 - [21] S. Sukumar, M. Marsadek, K. Agileswari, and H. Mokhlis, “Ramp-rate control smoothing methods to control output power fluctuations from solar photovoltaic (pv) sources—a review,” *Journal of Energy Storage*, vol. 20, pp. 218–229, 2018.
 - [22] G. Energy, “Western wind and solar integration study,”
 - [23] S. D. Miller, M. A. Rogers, J. M. Haynes, M. Sengupta, and A. K. Heidinger, “Short-term solar irradiance forecasting via satellite/model coupling,” *Solar Energy*, vol. 168, pp. 102–117, 2018. Advances in Solar Resource Assessment and Forecasting.

-
- [24] J. Lago, K. De Brabandere, F. De Ridder, and B. De Schutter, “Short-term forecasting of solar irradiance without local telemetry: A generalized model using satellite data,” *Solar Energy*, vol. 173, pp. 566–577, 2018.
- [25] Z. Zhen, J. Liu, Z. Zhang, F. Wang, H. Chai, Y. Yu, X. Lu, T. Wang, and Y. Lin, “Deep learning based surface irradiance mapping model for solar pv power forecasting using sky image,” *IEEE Transactions on Industry Applications*, vol. 56, no. 4, pp. 3385–3396, 2020.
- [26] S. Tiwari, R. Sabzehgar, and M. Rasouli, “Short term solar irradiance forecast using numerical weather prediction (nwp) with gradient boost regression,” in *2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG)*, pp. 1–8, 2018.
- [27] P. Mathiesen, C. Collier, and J. Kleissl, “A high-resolution, cloud-assimilating numerical weather prediction model for solar irradiance forecasting,” *Solar Energy*, vol. 92, pp. 47–61, 2013.
- [28] A. Ayet and P. Tandeo, “Nowcasting solar irradiance using an analog method and geostationary satellite images,” *Solar Energy*, vol. 164, pp. 301–315, 2018.
- [29] A. T. Lorenzo, M. Morzfeld, W. F. Holmgren, and A. D. Cronin, “Optimal interpolation of satellite and ground data for irradiance nowcasting at city scales,” *Solar Energy*, vol. 144, pp. 466–474, 2017.
- [30] J. Schmid, “The seviri instrument,” 2000.
- [31] H.-Y. Cheng, “Cloud tracking using clusters of feature points for accurate solar irradiance nowcasting,” *Renewable Energy*, vol. 104, pp. 281–289, 2017.
- [32] A. Al-lahham, O. Theeb, K. Elalem, T. A. Alshawi, and S. A. Alshebeili, “Sky imager-based forecast of solar irradiance using machine learning,” *Electronics*, vol. 9, no. 10, 2020.
- [33] D. Yang, J. Kleissl, C. A. Gueymard, H. T. Pedro, and C. F. Coimbra, “History and trends in solar irradiance and pv power forecasting: A preliminary assessment and review using text mining,” *Solar Energy*, vol. 168, pp. 60–101, 2018. Advances in Solar Resource Assessment and Forecasting.
- [34] S. Mazzola, C. Vergara, M. Astolfi, V. Li, I. Perez-Arriaga, and E. Macchi, “Assessing the value of forecast-based dispatch in the operation of off-grid rural microgrids,” *Renewable Energy*, vol. 108, pp. 116–125, 2017.
- [35] R. H. Inman, H. T. Pedro, and C. F. Coimbra, “Solar forecasting methods for renewable energy integration,” *Progress in Energy and Combustion Science*, vol. 39, no. 6, pp. 535–576, 2013.

- [36] Y. Li, Y. Su, and L. Shu, “An armax model for forecasting the power output of a grid connected photovoltaic system,” *Renewable Energy*, vol. 66, pp. 78–89, 2014.
- [37] F. Wang, Z. Mi, S. Su, and H. Zhao, “Short-term solar irradiance forecasting model based on artificial neural network using statistical feature parameters,” *Energies*, vol. 5, no. 5, pp. 1355–1370, 2012.
- [38] N. Dong, J.-F. Chang, A.-G. Wu, and Z.-K. Gao, “A novel convolutional neural network framework based solar irradiance prediction method,” *International Journal of Electrical Power & Energy Systems*, vol. 114, p. 105411, 2020.
- [39] A. Aljanad, N. M. L. Tan, V. G. Agelidis, and H. Shareef, “Neural network approach for global solar irradiance prediction at extremely short-time-intervals using particle swarm optimization algorithm,” *Energies*, vol. 14, no. 4, 2021.
- [40] A. Tuohy, J. Zack, S. E. Haupt, J. Sharp, M. Ahlstrom, S. Dise, E. Grimit, C. Mohrlen, M. Lange, M. G. Casado, J. Black, M. Marquis, and C. Collier, “Solar forecasting: Methods, challenges, and performance,” *IEEE Power and Energy Magazine*, vol. 13, no. 6, pp. 50–59, 2015.
- [41] B. Juncklaus Martins, A. Cerentini, S. L. Mantelli, T. Z. Loureiro Chaves, N. Moreira Branco, A. von Wangenheim, R. Rüther, and J. Marian Arrais, “Systematic review of nowcasting approaches for solar energy production based upon ground-based cloud imaging,” *Solar Energy Advances*, vol. 2, p. 100019, 2022.
- [42] R. Marquez, H. T. Pedro, and C. F. Coimbra, “Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to anns,” *Solar Energy*, vol. 92, pp. 176–188, 2013.
- [43] M. Saleh, L. Meek, M. A. S. Masoum, and M. Abshar, “Battery-less short-term smoothing of photovoltaic generation using sky camera,” *IEEE Transactions on Industrial Informatics*, vol. 14, no. 2, pp. 403–414, 2018.
- [44] J. Kleissl, “Current state of the art in solar forecasting,” *UC Berkeley: California Institute for Energy and Environment (CIEE)*, 2010.
- [45] C. Feng and J. Zhang, “Solarnet: A sky image-based deep convolutional neural network for intra-hour solar forecasting,” *Solar Energy*, vol. 204, pp. 71–78, 2020.
- [46] B. Kurtz, F. Mejia, and J. Kleissl, “A virtual sky imager testbed for solar energy forecasting,” *Solar Energy*, vol. 158, pp. 753–759, 2017.
- [47] S. Kuszamaul, A. Ellis, J. Stein, and L. Johnson, “Lanai high-density irradiance sensor network for characterizing solar resource variability of mw-scale pv system,” in *2010 35th IEEE Photovoltaic Specialists Conference*, pp. 000283–000288, 2010.

- [48] T. L. D., M. A., H. J., L. K., S. T., and V. S., “Operation of tut solar pv power station research plant under partial shading caused by snow and buildings,” *International Journal of Photoenergy*, vol. 2013, 2013.
- [49] S. Achleitner, “Sips : Solar irradiance prediction system,” *IPSN-14 Proceedings of the 13th International Symposium on Information Processing in Sensor Networks*, pp. 225–236, 2014.
- [50] A. T. Lorenzo, W. F. Holmgren, M. Leuthold, C. K. Kim, A. D. Cronin, and E. A. Betterton, “Short-term pv power forecasts based on a real-time irradiance monitoring network,” in *2014 IEEE 40th Photovoltaic Specialist Conference (PVSC)*, pp. 0075–0079, 2014.
- [51] H. Schenk, T. Hirsch, M. Wittmann, S. Wilbert, L. Keller, and C. Prahl, “Design and operation of an irradiance measurement network,” *Energy Procedia*, vol. 69, pp. 2019–2030, 2015. International Conference on Concentrating Solar Power and Chemical Energy Systems, SolarPACES 2014.
- [52] I. M. Moreno-Garcia, E. J. Palacios-Garcia, V. Pallares-Lopez, I. Santiago, M. J. Gonzalez-Redondo, M. Varo-Martinez, and R. J. Real-Calvo, “Real-time monitoring system for a utility-scale photovoltaic power plant,” *Sensors*, vol. 16, no. 6, 2016.
- [53] S. H. Monger, E. R. Morgan, A. R. Dyreson, and T. L. Acker, “Applying the kriging method to predicting irradiance variability at a potential pv power plant,” *Renewable Energy*, vol. 86, pp. 602–610, 2016.
- [54] D. Yang, “On adding and removing sensors in a solar irradiance monitoring network for areal forecasting and pv system performance evaluation,” *Solar Energy*, vol. 155, pp. 1417–1430, 2017.
- [55] X. Chen, Y. Du, E. Lim, H. Wen, and L. Jiang, “Sensor network based pv power nowcasting with spatio-temporal preselection for grid-friendly control,” *Applied Energy*, vol. 255, p. 113760, 2019.
- [56] P. A., “Epic-roofnet: A sensor network testbed for solar irradiance measurement and analysis,” p. 147 – 150, 2020.
- [57] R. J. and P. E.E.M., “Cloud advection model of solar irradiance smoothing by spatial aggregation,” *Journal of Renewable and Sustainable Energy*, vol. 13, no. 3, 2021. All Open Access, Green Open Access.
- [58] K. Lappalainen and S. Valkealahti, “Experimental study of the maximum power point characteristics of partially shaded photovoltaic strings,” *Applied Energy*, vol. 301, p. 117436, 2021.
- [59] E. Lorenz, P. Guthke, A. Dittmann, N. Holland, W. Herzberg, S. Karalus, B. Müller, C. Braun, W. Heydenreich, and Y.-M. Saint-Drenan, “High resolution measurement network of global horizontal and tilted solar irradiance in southern germany with a new quality control scheme,” *Solar Energy*, vol. 231, pp. 593–606, 2022.

-
- [60] S. Julien, A. Sajadi, and B.-M. S. Hodge, “Hierarchical control of utility-scale solar pv plants for mitigation of generation variability and ancillary service provision,” *IEEE Transactions on Sustainable Energy*, pp. 1–1, 2022.
 - [61] J. Bosch, Y. Zheng, and J. Kleissl, “Deriving cloud velocity from an array of solar radiation measurements,” *Solar Energy*, vol. 87, pp. 196–203, 2013.
 - [62] J. Bosch and J. Kleissl, “Cloud motion vectors from a network of ground sensors in a solar power plant,” *Solar Energy*, vol. 95, pp. 13–20, 2013.
 - [63] I. Smithpeter, “A low-cost iot approach to real-time cloud motion detection,” p. 111 – 119, 2018. Cited by: 1.
 - [64] M. A. Mughal, S. Cui, H. Zhang, M. Carpinello, J. McManus, M. Moreira, and K. Pacheco, “Cloud motion vector system to detect clouds and forecast real-time photovoltaic system performance,” p. 2212 – 2216, 2021. Cited by: 1.
 - [65] V. Fung, J. L. Bosch, S. W. Roberts, and J. Kleissl, “Cloud shadow speed sensor,” *Atmospheric Measurement Techniques*, vol. 7, no. 6, pp. 1693–1700, 2014.
 - [66] G. M. Lohmann, A. Hammer, A. H. Monahan, T. Schmidt, and D. Heinemann, “Simulating clear-sky index increment correlations under mixed sky conditions using a fractal cloud model,” *Solar Energy*, vol. 150, pp. 255–264, 2017.
 - [67] C. Liu, H. Liu, Y. Liu, T. Li, and T. Wang, “Normalized cross correlation image stitching algorithm based on minimum spanning tree,” *Optik*, vol. 179, pp. 610–616, 2019.
 - [68] M. Jamaly and J. Kleissl, “Robust cloud motion estimation by spatio-temporal correlation analysis of irradiance data,” *Solar Energy*, vol. 159, pp. 306–317, 2018.
 - [69] A. W. Aryaputera, D. Yang, L. Zhao, and W. M. Walsh, “Very short-term irradiance forecasting at unobserved locations using spatio-temporal kriging,” *Solar Energy*, vol. 122, pp. 1266–1278, 2015.
 - [70] S. H. Monger, E. R. Morgan, A. R. Dyreson, and T. L. Acker, “Applying the kriging method to predicting irradiance variability at a potential pv power plant,” *Renewable Energy*, vol. 86, pp. 602–610, 2016.

CAPÍTULO 9

Apéndices

Apéndice I

Article

An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems

Manuel Jesús Espinosa-Gavira , Agustín Agüera-Pérez * , Juan José González de la Rosa ,
José Carlos Palomares-Salas and José María Sierra-Fernández

Research Group PAIDI-TIC-168: Computational Instrumentation and Industrial Electronics (ICEI), University of Cádiz, EPSA, Av. Ramón Puyol S/N, Algeciras, 11202 Cádiz, Spain;
manuel.espinosa@uca.es (M.J.E.-G.); juanjose.delarosa@uca.es (J.J.G.d.I.R.);
josecarlos.palomares@uca.es (J.C.P.-S.); josemaria.sierra@uca.es (J.M.S.-F.)

* Correspondence: agustin.aguera@uca.es

Received: 23 August 2018; Accepted: 3 October 2018; Published: 11 October 2018



Abstract: Very short-term solar forecasts are gaining interest for their application on real-time control of photovoltaic systems. These forecasts are intimately related to the cloud motion that produce variations of the irradiance field on scales of seconds and meters, thus particularly impacting in small photovoltaic systems. Very short-term forecast models must be supported by updated information of the local irradiance field, and solar sensor networks are positioning as the more direct way to obtain these data. The development of solar sensor networks adapted to small-scale systems as microgrids is subject to specific requirements: high updating frequency, high density of measurement points and low investment. This paper proposes a wireless sensor network able to provide snapshots of the irradiance field with an updating frequency of 2 Hz. The network comprised 16 motes regularly distributed over an area of 15 m × 15 m (4 motes × 4 motes, minimum intersensor distance of 5 m). The irradiance values were estimated from illuminance measurements acquired by lux-meters in the network motes. The estimated irradiances were validated with measurements of a secondary standard pyranometer obtaining a mean absolute error of 24.4 W/m² and a standard deviation of 36.1 W/m². The network was able to capture the cloud motion and the main features of the irradiance field even with the reduced dimensions of the monitoring area. These results and the low-cost of the measurement devices indicate that this concept of solar sensor networks would be appropriate not only for photovoltaic plants in the range of MW, but also for smaller systems such as the ones installed in microgrids.

Keywords: irradiance monitoring network; wireless sensor network; very short-term solar forecasting; microgrids; pyranometer; lux-meter; cloud enhancement

1. Introduction

Sensor networks are consolidating as promising data sources for future solar energy forecasting applications, particularly for local and very-short term applications. At these scales, solar instrumentation is focused on capturing the cloud motion, which is the main cause of irradiance variations. All-sky cameras and satellite imagery have been used for this purpose, but, due to the complexity and inaccuracies associated with the image-to-irradiance conversion process, solar sensor networks are gaining attention as a direct solution to capture the local irradiance field and its evolution [1]. This trend has been reinforced by the recent proliferation of meteorological and energy sensors and the developments in big data applications for smart energy management based

on information sharing among multiple systems. In this sense, Zhou et al. pointed to microgrids (MGs) as important emerging sources of solar measurements and main beneficiaries of solar forecasts derived from big data techniques [2]. Furthermore, MGs are considered to be key elements in the large-scale grid integration of solar energy since they are efficient in mitigating the negative effects associated with the intermittent PV generation. Forecasting tools specifically designed for MG energy management systems would be valuable for this purpose. However, Mazzola et al. indicated that, in small systems such as MGs, “the cost of the forecast service plus other automation infrastructure may not be economically justified” [3].

Solar sensor networks have been used in different studies, generally involving scales larger than the ones associated with MGs. Data are acquired by a set of sensors randomly distributed over the concerned area, and later processed to estimate the solar variability of the area or forecast the irradiance at a certain point. For instance, Gutierrez-Corea et al. used artificial neural networks to forecast the irradiance in a target station analyzing data from 30 stations within a radius of 100 km and a temporal resolution of 15 min [4]. Supported by 13 solar sensors distributed over an area of 20 km × 40 km, Lorenzo et al. used different persistence methods to forecast irradiance. The sensors included pyranometers and photodiodes which provided 1-s resolution data with a latency of 1 min [5]. The solar sensor network described in [6] covered a similar area, although, in this case, it comprised 24 stations more homogeneously distributed which provided data with a resolution of 1 min. The study has added value, as it is focused on the optimal design of a solar sensor network, which is a topic rarely addressed in solar research literature.

The local scale of MGs demands solar sensor networks with characteristics different to the ones described above. The main challenge is associated with the drastic variations of the PV generation produced by the clouds, which have a lower impact in larger power systems as a result of the well-known spatial smoothing effect [7]. In [8], it is concluded that reliable descriptions of the clouds required 625 measurement points over an area of 2.5 km × 2.5 km and temporal resolution of 10 s. The NREL radiometer grid of Hawaii, USA represents a good example of the applications of solar information at these spatial and temporal scales. The NREL Radiometer grid was composed of 17 LICOR LI-200 pyranometers distributed over an area of 1 km × 1 km. (The minimum, median and maximum intersensor distances were 86, 381 and 1130 m, respectively [9]). Solar radiation was acquired with a resolution of 1 s and synchronized by GPS receivers. The versatility and usefulness of these data are corroborated by their utilization in forecasting applications [9], variability characterizations [10] and instantaneous irradiance estimations [11]. In [12], the solar sensor network of Melpitz, Germany was composed of 50 silicon photodiode pyranometers distributed over an area on 2 km × 2 km, achieving a maximum density in a central area of 0.5 km × 0.5 km where 25 pyranometers were installed (The shortest intersensor distances ranged from 28 m to 51 m [12]). Data were acquired at 10 Hz, stored as 1-s averaged values and subsequently analyzed to determine the irradiance variability and the spatial smoothing effects for PV-power integration. The NextEra Project deployed a grid of 48 pyranometers, each of them associated to a data-logger recording 1-s irradiance data, distributed over one square-mile in Flagstaff, Arizona. It is concluded that four stations would be enough to reasonably estimate the solar resource variability at a given site. The irradiance measurement network at the Plataforma Solar de Almería, Spain comprised 20 pyranometers distributed over 350 m × 280 m measuring at 1 Hz. The network design and its utilization for detecting cloud motion are described in [13].

Even if these studies deal with the local irradiance field, the concerned monitoring areas are significantly larger than the ones available for PV systems in MGs or nanogrids, commonly installed on building rooftops. The necessity and characteristics of solar data specifically focused on these systems are outlined in some studies. Lohmann et al. explained how smaller PV systems require more spatiotemporal resolution [12] and Scolari et al. pointed that MG energy management systems would be benefited by solar information in the sub-second range [14], but Torregrossa et al. stressed that little research has been done in this aspect [15]. In [16], the acquisition of this information is

considered a main challenge to reinforce the solar forecasts used by MG energy management systems. To the authors' knowledge, in the scientific literature, there are no examples of irradiance monitoring networks with dimensions of tens of meters and sub-second sampling.

For a proper design of irradiance monitoring networks with sub-second sampling, the sensors' time response must be carefully considered. Typically, the time response of the pyranometers ranges between 5 and 20 s, thereby acting as a low-pass filter for sub-second irradiance variations that affects the PV generation. In [17], Yordanov et al. compared the response of a pyranometer and a PV cell, showing how the pyranometer was not able to capture the peaks and fast variations of irradiance observed in the PV cell. These peaks and variations are mostly related to over irradiance events produced by the clouds' edges that can last from seconds to minutes, reaching peaks up to 2000 W/m² and requiring sampling frequencies of 1 Hz or higher to be accurately captured. Tapakis and Charalambides also studied these events, including a discussion of their effects in PV-inverters [18]. In this sense, it is asserted that the over irradiance events can produce irreparable damages to inverters, and indicated that they could be prevented by supplying high frequency measurements to the MPPT devices. Thus, both studies [17,18] emphasized the necessity of sensors able to work in these irradiance and temporal ranges to improve the PV-inverters operation. Lux-meters can be an interesting solution regarding time response and investment in these cases. Schenk et al. considered lux-meters in preliminary design stages of the irradiance network at the Plataforma Solar de Almería, Spain, reporting promising results in some cases and anomalous behaviors in others [13]. The results of these studies are further discussed below.

This paper deals with the design and test of a solar sensor network adapted to the necessities of small-scale PV systems. According to the above considerations, the network should provide on-line, sub-second measurements and an appropriate spatial resolution to support very short-term forecasting applications. The network should also be able to capture the over irradiance events produced by the clouds' edges to prevent damages in PV-inverters. Additionally, it should demand an easy-to-implement infrastructure and a low investment appropriated to the scale of the concerned systems. In this sense, wireless communications are chosen to minimize installation problems and costs. The paper is structured as follows. Section 2 describes the motes and the different elements involved in their design and construction. Section 3 explains the calibration process to adjust the illuminance-to-irradiance conversion, and providing a characterization of the accuracy of the measurements. Section 4 focuses on the configuration of the network, and Sections 5 and 6 contain the description of the results and conclusions, respectively.

2. Motes description

The WSN is composed of motes that basically comprise a solar sensor and a communication module powered by a battery and a PV panel to assure autonomous operation (Figure 1). As stated in [19], the two main components that affect the power consumption in WSN motes are the microcontroller and the radio module. To minimize the cost and power consumption, the design effort has been focused on developing motes without external microcontroller. As explained in [20], this concept also increases reliability (lower number of elements and interactions), flexibility (reconfigurations are easier and faster) and data rates (bottlenecks due to the external microcontroller are avoided) in the deployed networks. Note that these properties are critical in the present case, since simplicity and high data rates must be primary characteristics of solar sensor networks at local scale.

Regarding the environmental variables, irradiance is inferred from illuminance measurements provided by SFH 5711 sensors. This sensor is analogous to SFH 5712 which has been previously used in solar energy applications [13,21]. SFH 5711 differs from SFH 5712 in the output mode. The first has a logarithmic current output while the second has an I2C interface to read the measurement. Both are widely used in commercial devices as a sunlight sensor and precise lux-meter. Finally, a NTC termistor, ND03N00103K from AVX, is used for temperature measurements.

The communication is based on ZigBee/IEEE 802.15.4 protocol. Concretely, the XB24CZ7SIT-004 XBee module (included in XBee S2 Series RF modules) has been used, which a priori fulfills the network requirements of intersensor distances, data rates and investment. The selected XBee module support two working modes: AT and API. AT mode (or transparent mode) works like a wireless UART communication. On the other hand, API (Application Programming Interface) mode requires a specific UART data structure. API mode allows accessing the I/O interface and the subsequent parameter modification without entering the command mode and, thereby offering advantages over the AT mode (The API data structure can be consulted in [22]).

The main PCB holds the circuitry for interconnection among elements, including a battery management integrated circuit for safe charging of the Li-Po battery (2300 mAh, 3.7 V), a switching voltage regulator to power up the radio module and the signal conditioning circuitry and a N-channel MOSFET used as switch to power up the sensors PCB only when is needed, avoiding unnecessary battery drain. The radio module is also assembled to the main PCB, and both allocated inside an IP66 box together with the Li-Po battery. A power switch is added to the box for manual activation. The sensor PCB is placed inside a transparent case glued and sealed with silicone to the upper side of the IP66 box to allow direct light measurements. Finally, the PV solar panel (5 Wp) is also situated outside the box.

The total cost of each mote is below 5% of the cost of a secondary standard pyranometer.

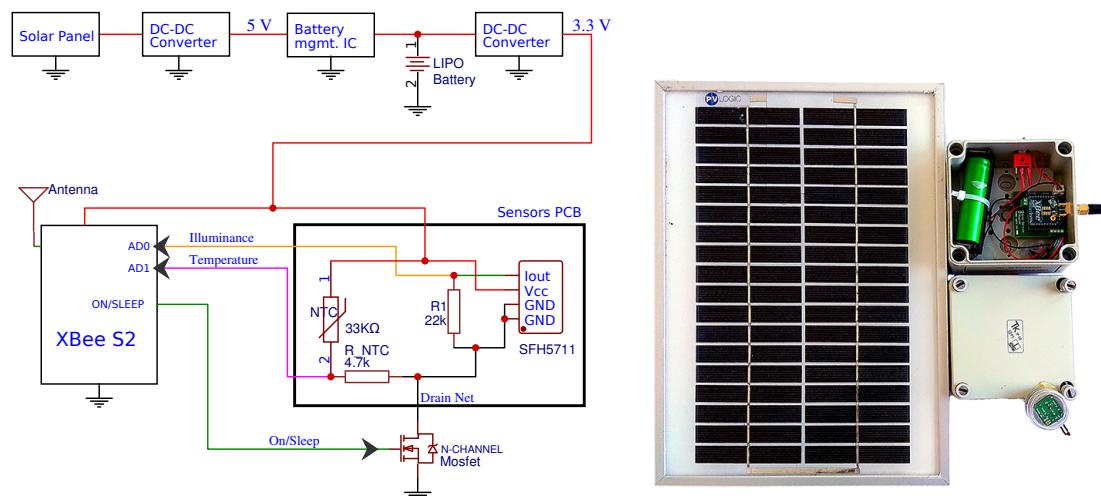


Figure 1. Mote schematics (left); and hardware prototype (right).

3. Calibration

An inference process is necessary to efficiently estimate irradiance values from the illuminance measurements provided by the lux-meter. The accuracy in these estimations determine the validity of the network for solar irradiance monitoring. For this purpose, a secondary standard pyranometer (CMP11 Kipp & Zonen) has been used as reference. Table 1 summarizes the main characteristics of the pyranometer and lux-meters (More information about the pyranometer and lux-meter can be found in [23,24]).

The pyranometer and 16 motes were closely installed in the rooftop of the Polytechnic School of Engineering in Algeciras, Spain (Latitude: 36.12° N; Longitude: 5.45° W), conforming a network similar to the one described in Section 4. Thus, the calibration conditions were similar to those of the real operation of the monitoring system. Data from a total of 12 h were used for calibration. These data were acquired at 2 Hz in periods of 30 min within a week (5–11 June 2018) trying to capture different meteorological situations associated with different degrees of cloud cover. Figure 2 shows pyranometer data of six 30-min periods as representative examples of the calibration conditions. Note

that in some cases the irradiance values are clearly above the expected maximum values under clear sky conditions, which is approximately 1000 W/m^2 . These values can be explained as over irradiance events produced by the clouds' edges.

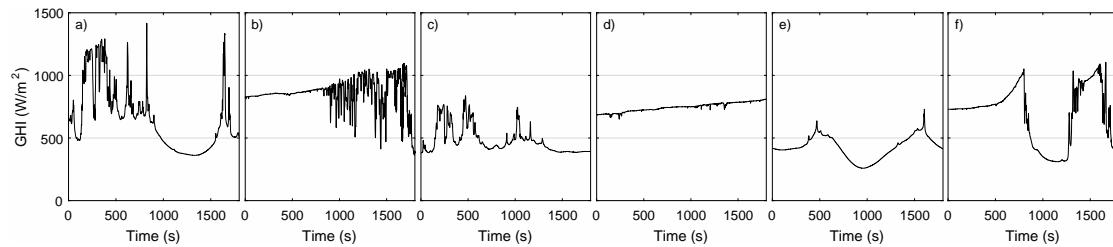


Figure 2. Six examples of real irradiance profiles used for calibration. The starting dates and times expressed in UTC+2 in each case: (a) 7 June 2018 13:20:42; (b) 8 June 2018 11:21:49; (c) 9 June 2018 09:48:22; (d) 9 June 2018 10:44:52; (e) 10 June 2018 12:35:15; and (f) 11 June 2018 11:00:46.

Table 1. Specifications.

	CMP11	SFH 5711
Measurement Range	0 to 4000 W/m^2	3 to 80 klx (*)
Spectral range	285 to 2800 nm	475 to 650 nm
Sensitivity	$7.66 \mu\text{V}/\text{W/m}^2$ (**)	$S = 10 \mu\text{A}/\text{dec}$ (***)
Response time	<5 s	<0.1 ms
Field of view	180°	180°

(*) Range in which the logarithmic relation is assured; (**) From the calibration document provided with the pyranometer; and (***) $I_{out} = S \cdot \log(E_v / E_0)$ where E_v is the input illuminance and $E_0 = 1 \text{ lx}$.

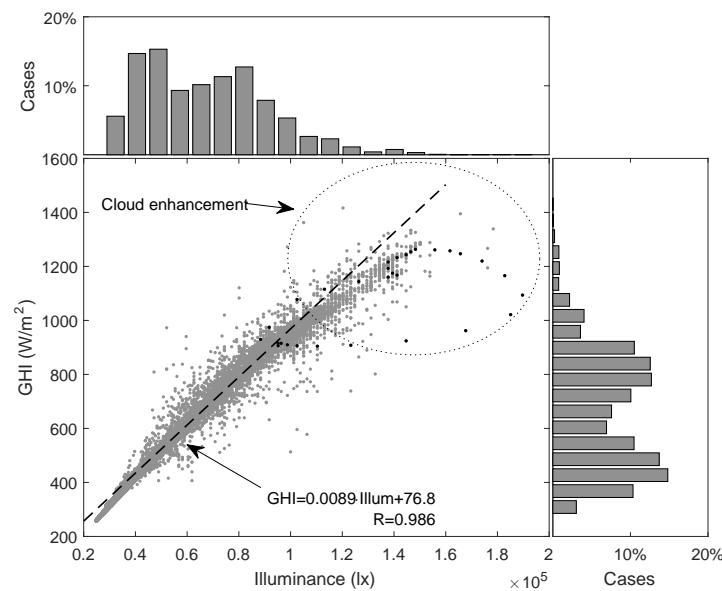


Figure 3. Scatter plot and histograms associated with the pyranometer and lux-meter #6 associated with the whole period used for calibration.

Once the data from the pyranometer and the motes were acquired, an individual calibration of each mote was performed. Since data showed excellent correlation in all cases—correlations coefficients (R) ranged from 0.975 to 0.991—the illuminance-to-irradiance conversion was adjusted by linear regression. Thus, a linear model was associated with each node to perform individualized

irradiance estimations. Figure 3 shows one representative case involving a correlation coefficient $R = 0.986$. The figure includes the corresponding regression line and its equation. Data are well-fitted by regression line for most of the measurement range, although certain deviation can be observed below 400 W/m and above 1200 W/m. Enclosed in a circle, there are points that can be associated with the already commented over irradiance events. These points represented less than 2% of the registers. Histograms at the top and right side of the scatter plot illustrate about the measurements distribution. The black dots are used to remark the detail represented in Figure 4, which is discussed below. Overall, the scatter plots of the resting 15 motes present similar features. Table 2 details the results for each mote.

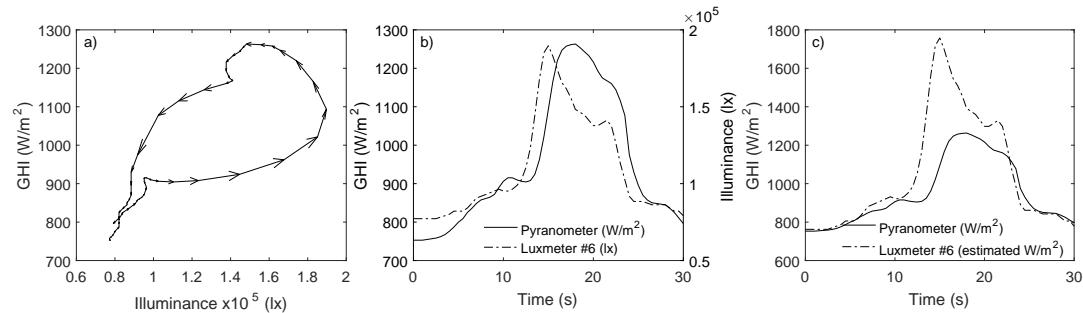


Figure 4. Analysis of the pyranometer and lux-meter #6 performances during a cloud enhancement event: trajectory in the scatter plot (a); comparison of measured illuminance and irradiance in the time domain (b); and comparison of estimated and measured irradiance in the time domain (c).

The scatter plots used in the calibration process present peculiar curves that, to a greater or lesser extent, are responsible for a relevant part of the dispersion observed between the pyranometer and mote registers. These curves were also reported by Schenk et al. and interpreted as anomalous behavior of some lux-meters. The result was the exclusion of these sensors from their solar sensor network despite the promising results in some cases and the low investment costs [13]. These anomalous curves can be produced by the different time response between the pyranometers and lux-meters: the former in the range of seconds and the latter in the range of milliseconds. To illustrate, Figure 4a shows one of these curves extracted from the scatter plot of Figure 3. The arrows indicate the sequence of the 61 selected points, corresponding to a period of 30 s (sampling frequency of 2 Hz). Figure 4b reproduces the concerned GHI and illuminance measurements in the time domain. The selected interval covers a moment of clear sky between clouds. Figure 4b shows how the lux-meter captured the drastic changes approximately two seconds before the pyranometer reaction. Thus, in a first step, there is an increase of luxes without increase of irradiance, which produces a horizontal trajectory in the scatter plot (Figure 4a). As pyranometer reacts, the trajectory becomes more vertical. Following the sequence of measurements, the entire curve can be reproduced. Finally, as the values remain stable due to the presence of the new cloud, the points converged to the initial ones. Besides the commented “delay”, Figure 4b also shows how the lux-meter measurements present more details, while the pyranometer measurements are smoother. The illuminance-to-irradiance conversion described above allows to compare the performance of both sensors (lux-meter #6 and pyranometer) in terms of irradiance, as represented in Figure 4c. The longer time response of the pyranometer acts as a low-pass filter that smooths fast irradiance variations, thereby omitting irradiance events that occurs in shorter time scales. The lux-meter is able to capture these rapid changes, registering remarkable features as irradiance peaks 50% higher than the ones measured by the pyranometer. Under stable conditions or slow variations of irradiance, both sensors provide similar measurements. These results indicate that lux-meters can provide measurements more representative of the PV-cell behavior in the sub-second range, thereby being even more suitable than pyranometers for monitoring systems at these scales.

Figure 5a shows the error distribution resulting from the aggregation errors from the 16 motes, which provides a general characterization of the expected accuracy in these sensors. The error distribution presents a standard deviation of 36.1 W/m^2 , being the 95% of errors within a range of 68.1 W/m^2 . The mean absolute error is 24.4 W/m^2 . Figure 5b and Table 2 shows the individualized results for each mote. It is worth mentioning that these errors provide a conservative characterization of the mote's performance, since they include the commented deviations derived from the time response that, in some sense, can be interpreted as pyranometer's errors. Anyway, for characterization purposes, the pyranometer data have been considered as an exact reference. In this sense, the observed errors also compute the effects of all the uncertainty sources that affect the measurement chain: data acquisition strategy, transmission problems or different performances under different atmospheric conditions. The obtained uncertainty is thereby a characterization of the performance of the motes and the monitoring system as a whole. A deeper analysis on the effects of the different uncertainty sources would be matter of future work.

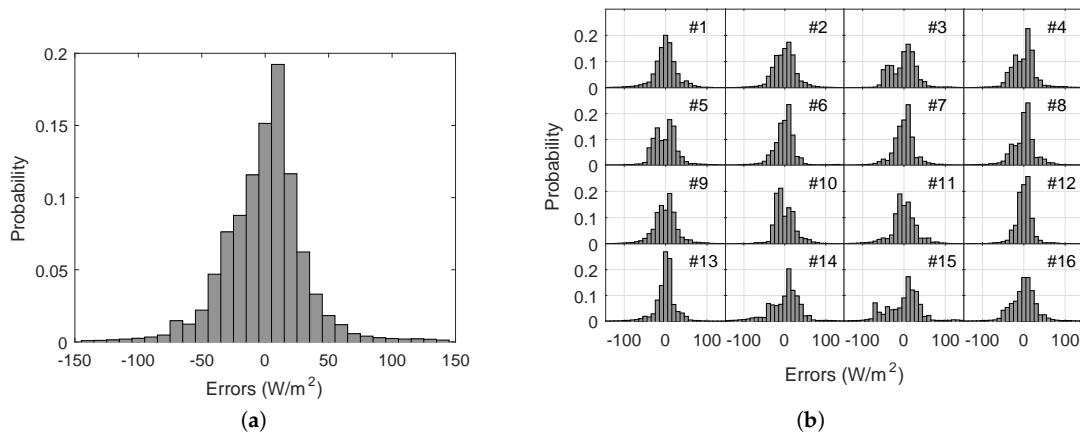


Figure 5. Aggregated error distribution including the 16 motes (a); and error distributions for each mote according to the network layout (b).

Table 2. Motes.

	MAE (W/m^2)	SD (W/m^2)	R		MAE (W/m^2)	SD (W/m^2)	R
Mote #1	24.4	40.4	0.983	Mote #9	25.2	39.9	0.983
Mote #2	24.8	38.4	0.984	Mote #10	21.1	27.6	0.990
Mote #3	26.9	36.9	0.986	Mote #11	25.6	40.9	0.982
Mote #4	24.8	39.0	0.984	Mote #12	16.0	25.4	0.991
Mote #5	25.3	36.5	0.983	Mote #13	18.5	30.0	0.991
Mote #6	20.7	32.8	0.986	Mote #14	32.2	47.3	0.976
Mote #7	20.2	29.3	0.991	Mote #15	35.3	48.6	0.975
Mote #8	23.7	38.8	0.984	Mote #16	25.6	38.6	0.984

4. Network Configuration

XBee modules are thought to build mesh networks. In a first stage, the mesh architecture was considered and the motes were configured to work as measurement devices and routers simultaneously. In these conditions, we found problems to increase the sampling frequency above 1 Hz. Furthermore, the network performance was highly unstable and similar experiments provided very different results. The reception of packets was irregular among the 16 motes and variable in time, making impossible the implementation of an irradiance monitoring network for the proposed objectives. Thus, the router role was disabled and the motes were set as measurement end devices only, showing an important improvement in their data acquisition properties. However, this configuration also required the inclusion of additional devices acting as routers to link the motes and the coordinator, which in turns

transmitted the information to the PC through a serial port. The routers were identical to the motes but removing the sensors and the associated circuitry. With this configuration, the packets followed a mote–router–coordinator path, giving uniformity to the information flow from each mote.

To determine the network optimal operation conditions, a series of tests were performed involving different sub-second sampling periods and different numbers of routers. Figure 6 summarizes the results of these tests. The characterization of the network operation was based on three factors:

- The ratio of successfully received packets, as the relation between the received packets and the packets that have been sent according to the established sampling period (see Figure 6a): A ratio of 1 involves that all sent packets were received.
- The temporal dispersion of the received packets, quantified by the standard deviation in the time between packets (see Figure 6b): A low standard deviation is associated with a high periodicity, indicating a stable flow of information from the motes to the coordinator.
- The mean delay in the reception of packets, as the difference between the motes sampling period and the actual mean period between received packets (see Figure 6c): The mean delay is associated with the computation time and possible transmission delays, which are added to the sampling period of each mote.

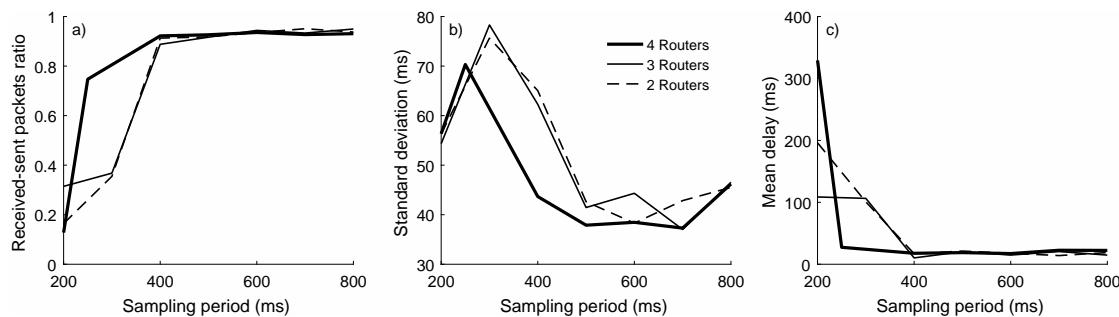


Figure 6. Network performance under different configurations: (a) Received-sent packets ratio, (b) Standard deviation and (c) Mean delay in the reception of packets.

The ideal situation would be associated with a ratio of successfully received packets of 1 and a standard deviation and mean delay of 0 ms in the time reception of packets. This would imply that all sent packets are received with a regular periodicity equal to the selected sampling period. The results in Figure 6 show that sampling periods shorter than 400 ms entail an important percentage of lost packets that obviously introduces dispersion and delay in the reception of packets. With longer sampling periods, the network became stable and the performances including two, three or four routers were similar, with the received-sent packet ratios close to the unity and mean delays around 20 ms in all cases. The presence of four routers only seems to slightly benefit the regular reception of packets.

Attending to these results, the final network configuration had the following characteristics:

- Sixteen motes act as end devices distributed on a regular grid of $15\text{ m} \times 15\text{ m}$ (minimum intersensor distance of 5 m).
- Four routers channel information to the coordinator. The network was initialized by linking four motes to each router, but momentarily variations of this configuration were observed. Despite the minimum improvement associated with four routers, the redundancy of nodes ensured a more relaxed network operation and robustness against possible disconnections without a significant increase of costs.
- A sampling period of 480 ms was established. Thus, the addition of 20 ms related to the observed delays results in an actual sampling period of 500 ms (2 Hz).

5. Results

The estimation and final representation of the irradiance field are performed on a PC that receives the information packets from the motes through a serial port via the coordinator. The buffer is read every 500 ms and the received packets are individually processed. The illuminance measurements within these packets are converted to irradiance values by applying the specific linear model associated with each mote that sent each packet (see Section 3). Then, the irradiance values are represented in a 4×4 matrix according to the spatial position of each mote. Thus, the representation of the irradiance field is updated every 500 ms (Even though measurements from all motes are refreshed every 500 ms, the acquisition of data is not synchronized. The uncertainty derived from the de-synchronization is included in the errors evaluation in Section 3, as the calibration process was performed under measurement and communication conditions similar to those of the real operation of the system). Due to the temporal dispersion of packets—around 40 ms (see Section 4)—in some cases, two packets from the same mote can be received in a 500-ms interval. In these cases, the last received packet is selected to represent the most updated information. Similarly, there are 500-ms intervals in which no packet has been received from a certain mote. Then, the value of the concerned mote in the previous interval is maintained.

Once the network was installed and configured, several tests were carried out to verify the system's ability in capturing the cloud motion. As preliminary results, the tests confirmed the stability of the network and the normal operation according to the design specifications. It was also corroborated that the motes' energy demand was satisfied by the PV panel (5 W_p), thus assuring autonomy (The state of charge of the batteries never was below 60%).

Figure 7a shows the estimated irradiances associated with the 16 motes in a period of 10 min (600 s). The measurements show consistency and illustrate about the general performance of the network under variable irradiance conditions. However, this information must be analyzed in the sub-second range to certify its utility in very short-term forecasts for small scale PV systems. In this sense, the right figure details the most significant irradiance variation in this period: a cloud enhancement event occurred between the Seconds 495 and 510. It can be observed how the event is clearly registered by all motes but with different intensity and slight temporal shift. For a better interpretation of these data, Figure 8 represents the sequence of the event according to the spatial position of each mote in the grid. This visualization clearly reveals the advance of the clouds in NW direction, which explains the temporal shift observed in the motes measurements. The sequence confirms that the sampling frequency and the density of measurement points were able to capture the cloud motion at these temporal and spatial scales.

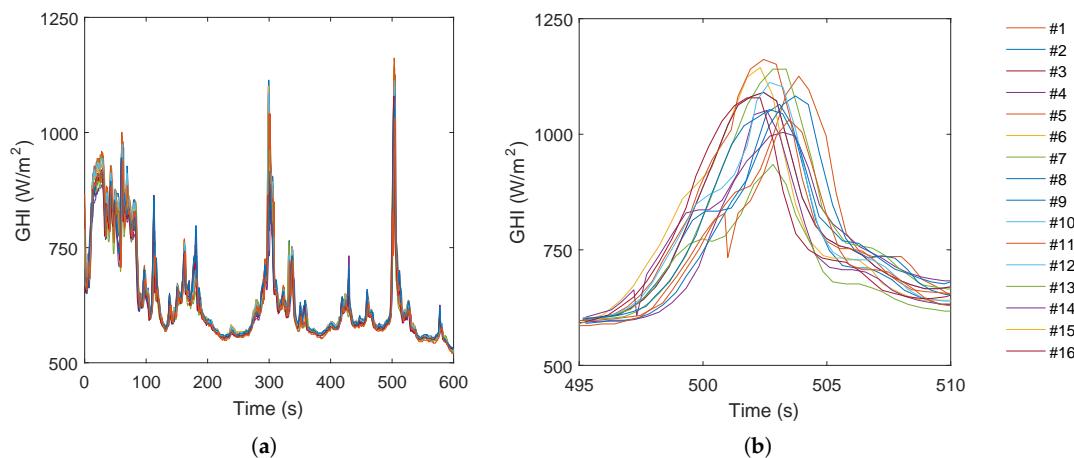


Figure 7. Estimated irradiance from the 16 motes: 10-min period (a); and 15-s detail (b).

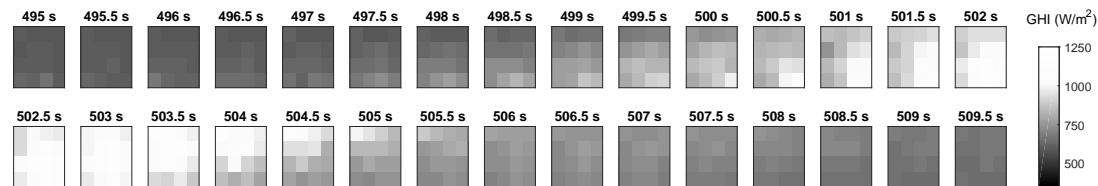


Figure 8. Irradiance field sequence of 15 s.

Figure 9 shows a 60-s sequence to give an idea of the continuous operation of the system. The sequence includes different situations from cloudy to clear conditions. Again, the cloud movement towards the NW can be observed. Some spatial features of the irradiance field can also be observed. For instance, during Seconds 15–18, a high irradiance zone passed over the monitoring area but mainly affecting the motes placed in the SW. The information provided by the sensor network can be a valuable input for very short-term forecasting applications. For instance, machine-learning techniques can be easily implemented to determine the current cloud velocities, and on this basis generate predictions for a central point (the PV panels) according to the irradiance variations observed at the outer motes.

Finally, it is worth mentioning that the motes were able to work autonomously entering in sleep mode during the nights only, indicating that the energy supply provided by a 5 Wp panel was enough for the motes and routers operation.

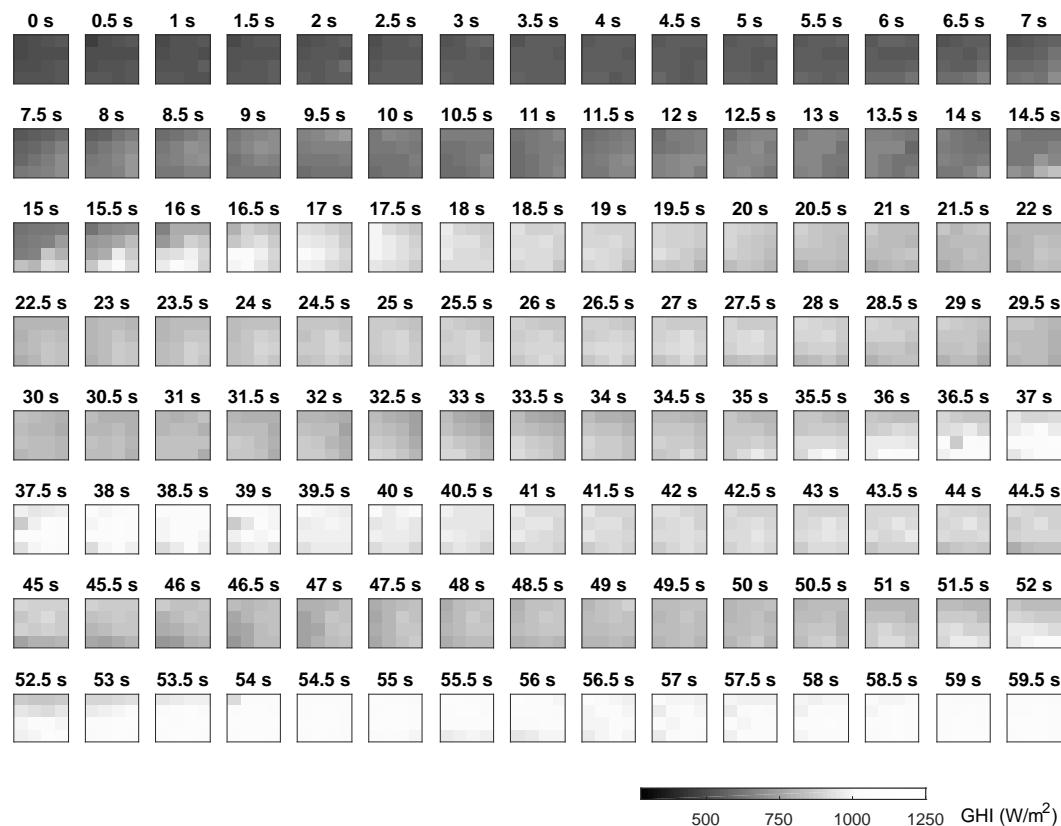


Figure 9. Irradiance field sequence of 60 s.

6. Conclusions

The present study described and tested an irradiance monitoring system adapted to the restrictive necessities of MGs or small-scale PV systems. These necessities can be summarized as sub-second

sampling frequency, high density of measurement points and a low investment. The monitoring system was designed as a wireless sensor network based on the ZigBee protocol comprising 16 motes regularly distributed over an area of $15\text{ m} \times 15\text{ m}$. The irradiance values were inferred from illuminance measurements acquired by lux-meters installed in each mote. After the calibration process, the inferred irradiance values showed a mean absolute error of 24.4 W/m^2 and a standard deviation of 36.1 W/m^2 with respect to the measurements of a secondary standard pyranometer used as reference. The sampling frequency was set at 2 Hz since higher frequencies produced instability in the network operation worsening the information flow. In these conditions, the monitoring system was able to capture the irradiance variations associated with the cloud motion with enough temporal and spatial resolution to outline the main features of the irradiance field and its evolution, including over irradiance events produced by the clouds' edges. The results indicate that monitoring systems with these characteristics could provide excellent support for very short-term forecasting applications that benefit the operation of small PV systems with a low investment, and consequently also applicable to larger systems.

Collaterally, the effect of the pyranometer's time response in smoothing the rapid irradiance variations was also observed, indicating that lux-meters are probably a better option for detailed sub-second irradiance measurements. The difference between both sensors was clear during cloud enhancement events.

Author Contributions: M.J.E.-G. designed the hardware. M.J.E.-G. and A.A.-P. conceived and performed the experiments, analyzed the data and wrote the paper. J.J.G.d.I.R., J.C.P.-S. and J.M.S.-F. contributed reagents and network implementation and helped review the state of the art.

Funding: This work was supported by the Spanish Ministry of Economy, Industry and Competitiveness grant number TEC2016-77632-C3-3-R. The authors would like to thank the Andalusian Government for funding the Research Unit PAIDI-TIC-168.

Conflicts of Interest: The authors declare no conflict of interest

Abbreviations

The following abbreviations are used in this manuscript:

GHI	Global horizontal irradiance
MAE	Mean absolute error
MG	Microgrid
MPPT	Maximum power point tracking
PCB	Printed circuit board
PV	Photovoltaic
PC	Personal computer
SD	Standard deviation

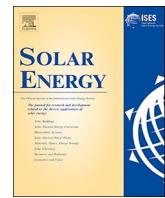
References

1. Yang, D.; Kleissl, J.; Gueymard, C.A.; Pedro, H.T.; Coimbra, C.F. History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Sol. Energy* **2018**. [[CrossRef](#)]
2. Zhou, K.; Fu, C.; Yang, S. Big data driven smart energy management: From big data to big insights. *Renew. Sustain. Energy Rev.* **2016**, *56*, 215–225. [[CrossRef](#)]
3. Mazzola, S.; Vergara, C.; Astolfi, M.; Li, V.; Perez-Arriaga, I.; Macchi, E. Assessing the value of forecast-based dispatch in the operation of off-grid rural microgrids. *Renew. Energy* **2017**, *108*, 116–125. [[CrossRef](#)]
4. Gutierrez-Corea, F.V.; Manso-Callejo, M.A.; Moreno-Regidor, M.P.; Manrique-Sancho, M.T. Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations. *Sol. Energy* **2016**, *134*, 119–131. [[CrossRef](#)]

5. Lorenzo, A.T.; Holmgren, W.F.; Cronin, A.D. Irradiance forecasts based on an irradiance monitoring network, cloud motion, and spatial averaging. *Sol. Energy* **2015**, *122*, 1158–1169. [[CrossRef](#)]
6. Yang, D. On adding and removing sensors in a solar irradiance monitoring network for areal forecasting and PV system performance evaluation. *Sol. Energy* **2017**, *155*, 1417–1430. [[CrossRef](#)]
7. Basak, P.; Chowdhury, S.; nee Dey, S.H.; Chowdhury, S. A literature review on integration of distributed energy resources in the perspective of control, protection and stability of microgrid. *Renew. Sustain. Energy Rev.* **2012**, *16*, 5545–5556. [[CrossRef](#)]
8. Jamaly, M.; Kleissl, J. Robust cloud motion estimation by spatio-temporal correlation analysis of irradiance data. *Sol. Energy* **2018**, *159*, 306–317. [[CrossRef](#)]
9. e Silva, R.A.; Brito, M.C. Impact of network layout and time resolution on spatio-temporal solar forecasting. *Sol. Energy* **2018**, *163*, 329–337. [[CrossRef](#)]
10. Anvari, M.; Werther, B.; Lohmann, G.; Wächter, M.; Peinke, J.; Beck, H.P. Suppressing power output fluctuations of photovoltaic power plants. *Sol. Energy* **2017**, *157*, 735–743. [[CrossRef](#)]
11. Widén, J.; Shepero, M.; Munkhammar, J. On the properties of aggregate clear-sky index distributions and an improved model for spatially correlated instantaneous solar irradiance. *Sol. Energy* **2017**, *157*, 566–580. [[CrossRef](#)]
12. Lohmann, G.M.; Monahan, A.H.; Heinemann, D. Local short-term variability in solar irradiance. *Atmos. Chem. Phys.* **2016**, *16*, 6365–6379. [[CrossRef](#)]
13. Schenk, H.; Hirsch, T.; Wittmann, M.; Wilbert, S.; Keller, L.; Prahl, C. Design and Operation of an Irradiance Measurement Network. *Energy Procedia* **2015**, *69*, 2019–2030. [[CrossRef](#)]
14. Scolari, E.; Sossan, F.; Paolone, M. Irradiance prediction intervals for PV stochastic generation in microgrid applications. *Sol. Energy* **2016**, *139*, 116–129. [[CrossRef](#)]
15. Torregrossa, D.; Boudec, J.Y.L.; Paolone, M. Model-free computation of ultra-short-term prediction intervals of solar irradiance. *Sol. Energy* **2016**, *124*, 57–67. [[CrossRef](#)]
16. Agüera-Pérez, A.; Palomares-Salas, J.C.; de la Rosa, J.J.G.; Florencias-Oliveros, O. Weather forecasts for microgrid energy management: Review, discussion and recommendations. *Appl. Energy* **2018**, *228*, 265–278. [[CrossRef](#)]
17. Yordanov, G.H.; Midtgård, O.; Saetre, T.O.; Nielsen, H.K.; Norum, L.E. Overirradiance (Cloud Enhancement) Events at High Latitudes. *IEEE J. Photovolt.* **2013**, *3*, 271–277. [[CrossRef](#)]
18. Tapakis, R.; Charalambides, A. Enhanced values of global irradiance due to the presence of clouds in Eastern Mediterranean. *Renew. Energy* **2014**, *62*, 459–467. [[CrossRef](#)]
19. Vaquerizo-hdez, D.; Muñoz, P.; R-moreno, M.D.; Barrero, D.F. A Low Power Consumption Algorithm for Efficient Energy Consumption in ZigBee Motes. *Sensors* **2017**, *17*, 2179. [[CrossRef](#)]
20. Espinosa-Gavira, M.J.; Jimenez-Pro, A.; de-la Rosa, J.J.G.; Aguera-Perez, A.; Florencias-Oliveros, O.; Palomares-Salas, J.C.; Sierra-Fernandez, J.M. Improving Flexibility in Wireless Sensor Networks via API. An Application in Environmental Monitoring. In Proceedings of the 9th IFIP International Conference on New Technologies, Mobility and Security (NTMS), Paris, France, 26–28 February 2018. doi:10.1109/NTMS.2018.8328697.
21. Al-Dahoud, A.; Fezari, M.; Belhouchet, F.; Al-Rawashdeh, T.A. Remote monitoring system for solar power panels using intelligent sensors network. In Proceedings of the 24th Telecommunications Forum (TELFOR), Belgrade, Serbia, 22–23 November 2016.
22. ZigBee RF Modules. 2014. Available online: <https://www.digi.com/resources/documentation/digidocs/PDFs/90000976.pdf> (accessed on 10 October 2018).
23. Zonnen, K. CMP 11 Pyranometer. Available online: <http://www.kippzonen.com/Product/13/CMP11-Pyranometer#.W6ItregzbQ> (accessed on 10 October 2018).
24. opto semiconductors, O. Chipled SFH 5711. Available online: https://www.osram.com/os/ecat/CHIPLED%C2%AE%20SFH%205711/com/en/class_pim_web_catalog_103489/global/prd_pim_device_2219526/ (accessed on 10 October 2018).



Apéndice II



Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method



Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José-Carlos Palomares-Salas,
Juan-José González-de-la-Rosa, José-María Sierra-Fernández, Olivia Florencias-Oliveros

Research Group PAIDI-TIC-168: Computational Instrumentation and Industrial Electronics (ICEI), University of Cadiz, EPSA, Av. Ramón Puyol S/N, Algeciras, 11202 Cadiz, Spain

ARTICLE INFO

Keywords:
Irradiance monitoring
Cloud motion
Small-scale PV systems
Sensor networks

ABSTRACT

Small-scale PV generation is particularly affected by the irradiance variability produced by cloud shadows. Accurate predictions of the clouds passing over the PV field are thus necessary for the optimized management and integration of this renewable power source. Two main elements are required to perform these predictions: the local irradiance field and the cloud motion vector. Irradiance sensor networks are positioning as a promising data source at the spatial and temporal scales of the problem, avoiding the irradiance inference problems and costs of image-based instrumentation. This paper proposes a method to infer the cloud shadow motion vector from small-scale irradiance sensor networks data. The method does not require specific network configuration or layout, and the algorithm is computationally simple: graphical solutions are obtained by aggregating mean absolute errors in a diagram/matrix with each element representing a possible displacement of the cloud shadows. The validation is conducted with a fractal cloud model that allows the generation of irradiance time series according to an arbitrary cloud motion vector. The most correlated pair and the linear cloud edge methods are used for benchmarking purposes. Gridded and non-gridded sensors layouts are tested with number of sensors ranging from 9 to 100, monitored areas from 100 to 10000 m², and sampling periods from 0.3 to 3.3 s. The results show the superiority of the proposed method with a reduction of 50–90% of the root mean square errors respect to the benchmark methods in 75% of the tests. Additionally, the proposed method maintains similar performance as sampling rate decreases, while the benchmark methods exhibit worsening results.

1. Introduction

Small-scale PV systems represent an important part of the solar capacity installed in recent years. They are also gaining presence in energy research as they are intimately related to fundamental concepts of the smart grid, as distributed energy resources, microgrids, or prosumers. The International Energy Agency reported that 40% of the total installed PV capacity during 2017 was associated with decentralized systems, being the cumulative value significantly higher than the centralized one in some countries such as Germany, Australia, or Japan (IEA International Energy Agency, 2018). The effective integration of this renewable power demands energy management tools adapted to the particular characteristics of small-scale PV generation. One of these characteristics is the high short-term variability of the power output produced by the cloud shadows passing over the PV field. Larger systems present a lower variability as a result of the well-studied smoothing effect (Dyreson et al., 2014), but in small-scale PV systems the generation can vary 80% within seconds resulting in energy losses, power imbalances, unexpected power flows, or power quality problems (Yan and Saha, May 2012). Accurate forecasts in the range of seconds or

minutes are necessary to deal with this irradiance variability (Scolari et al., 2016; Torregrossa et al., 2016).

Short-term forecasting for small-scale PV systems requires information of the local irradiance field with enough temporal and spatial resolution to reproduce the irradiance transitions produced by the clouds' edges. These resolutions (in the order of meters and seconds) limit the use of satellite imagery, despite its potential as data source for solar applications. All-sky cameras provide high-resolution high-frequency images but they are limited by image-to-irradiance conversion problems. The irradiance sensor networks are gaining attention as a simple and reliable way to obtain irradiance data from an area, and the increasing necessity of ground truth (Yang et al., 2017). Thus, some recent research has been focused on PV predictions from irradiance networks at scale of districts (Anvari et al., 2017; e Silva and Brito, 2018; Lohmann et al., 2016) or cities (Lohmann et al., 2016; Yang, 2017). In the context of small-scale PV systems, the sensor networks entail a particular problematic since they are constrained by limited area (they are mostly installed in rooftops with obstacles) and limited investment (according to the cost of the PV system). The trade-off between the necessity of high-frequency measurements to support very-

<https://doi.org/10.1016/j.solener.2020.03.081>

Received 15 August 2019; Received in revised form 21 February 2020; Accepted 22 March 2020

Available online 07 April 2020

0038-092X/© 2020 International Solar Energy Society. Published by Elsevier Ltd. All rights reserved.

short-term forecasts and the associated communication and computational cost is also an important factor in the design of these networks. Two descriptive examples can be consulted in Lappalainen and Valkealahti (2016) and Espinosa-Gavira et al. (2018). The first study is based on a more sophisticated network deployed for research purposes which comprises 23 pyranometers distributed in a non-gridded configuration over an area of 50 × 50 m and a sampling frequency of 10 Hz. The second one described a gridded network of 16 sensors covering an area of 15 × 15 m and a sampling frequency of 2 Hz focused on testing the capability of low-cost devices to supply on-line irradiance information. Despite the main purpose being the management of the associated PV system, some review articles pointed the potential of these networks to support higher level PV predictions based on information sharing and big data applications (Yang et al., 2017; Zhou et al., 2016; Agüera-Pérez et al., 2018).

The cloud motion vector (CMV) is a fundamental input for local short-term predictions. However, inferring the CMV from sensors measurements is not a simple task. The CMV has been mostly estimated by applying the cross-correlation method (CCM) to images from satellites (Escrig et al., 2013; Alonso-Montesinos and Batllés, 2015) or all-sky cameras (Peng et al., 2015; Wang et al., 2018). The CCM is based on finding parts (or templates) of a previous image into an updated image. The observed displacements are used to calculate the CMV. Jamaly and Kleissl (2018) applied the CCM method to a grid of 128 × 128 points distributed over 2500 × 2500 m, with irradiance data generated by large eddy simulation. The deployment of an equivalent real-life sensor network involves serious practical inconveniences and may not be economically justified, but the CCM demonstrated a good performance in this theoretical scenario. The real-world small-scale networks are characterized by limited area, irregular layouts, and low number of sensors. This makes difficult the application of the CCM and other solutions developed by the computer vision community for optical flow estimations. Thus, the cloud velocity is estimated by using the most correlated pair (MCP) and the linear cloud edge (LCE) methods, which are based on the determination of time lags between measurements of a pair of sensors. This determination involves a high uncertainty since it is assumed that similar features are observed by different sensors, whereas actually they measure different parts and details of the cloud. Hence, the MCP and LCE methods implement strict quality control processes to deal with the dispersion of results. The performance of the MCP and LCE methods was compared in Bosch et al. (2013) and Bosch and Kleissl (2013) considering PV rooftop and facility scales, respectively. The MCP provided more stable results in both cases, and the graphical results showed a better performance of both methods in the small-scale context. Fung et al. (2014) implemented the LCE method in cloud shadow speed sensor of reduced dimensions (intersensor distance of 30 cm approx). In order to improve the cloud shadow sensor results, Wang et al. (2016) proposed the adaptation of the LCE including a curve fitting method for a better determination of lags. Kuhn et al. (Oct 2018) validated the resulting method with cloud shadow camera concluding that the effects of curve fitting “were found to be of minor importance”. Lappalainen and Valkealahti (2016) also implemented a

curve fitting method to improve the LCE performance in a rooftop monitoring network. The curve fitting method was assumed to minimize the uncertainty in the estimation of lags, but the improvement was not explicitly assessed. Smithpeter (2018) suggests a modification of the MCP which differs from the original method in the application of the simplex algorithm to the lags estimation.

This paper proposes a method for CMV estimations specifically adapted to small-scale irradiance sensor networks. Unlike the MCP or the LCE methods, the proposed method avoids the problems of the determination of time lags, and does not impose any assumption about the cloud shapes or displacements. The method is based on the periodic comparison of data from a sensor array. The calculations are simple and the solutions are obtained in a graphical way. The aggregation of results over a time period makes the method tolerant to misleading effects derived from the irradiance field characteristics at these scales. Furthermore, the application of spatial interpolation models makes the method adaptable to non-gridded networks. As additional contribution, the paper describe a synthetic validation framework based on fractal cloud models which allows the simulation of irradiance series with a known CMV. This synthetic framework can be used not only for testing and validation of CMV estimation methods, but also for simulations of cloud shadows effects in PV systems.

The paper is structured as follows. Section 2 provides the fundamental definitions and concepts that are referenced along the text, with the goal of contextualize the problem and facilitate further explanations. The MCP and LCE methods, used for benchmarking purposes, are described in Section 3. The Section 4 describes the proposal of the new method, driven by an analysis of the problems associated with the CCM. The results of the tests are detailed in Section 5. In Section 6, a generalization of the method for non-gridded networks based on kriging interpolation is proposed and tested. Finally, Section 7 contains the conclusions and outlines future research lines.

2. Preliminary considerations

2.1. Definitions

Let us consider a gridded irradiance monitoring network of n -by- n sensors with minimum intersensor distance of D and sampling period of T_s (see Fig. 1). The square covered by the monitoring network has a side length of $L = (n - 1) \cdot D$ and a density of measurement points $d = n^2/L^2$. Let us call S_t the spatial representation of the measurements acquired for the sensor network at time t (or snapshot at time t). Hence, two consecutive snapshots are represented by S_t and S_{t+T_s} since the time difference between them is T_s .

Let us assume a stable cloud (non-affected by formation or dissipation processes) moving with a velocity of $\vec{v} = (v_x, v_y)$, hereinafter CMV. The maximum cloud speed that can be detected by the monitoring network in any direction is given by the expression $v_{max} = L/T_s$, determined by a CMV aligned with one of the axis of the network. Higher speeds can be measured in other directions. For instance, the highest speed can be measured if the CMV is aligned with the diagonal

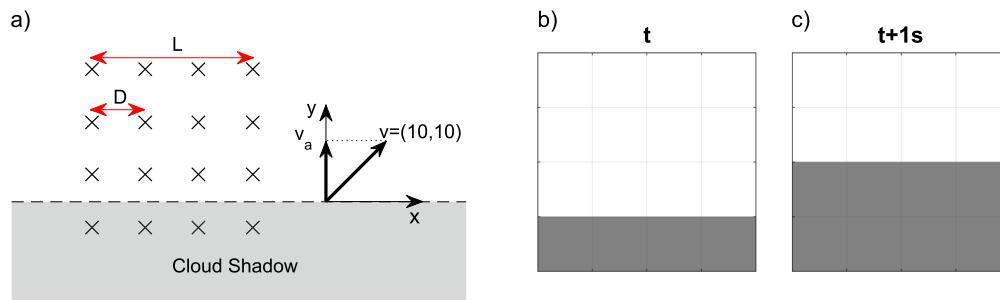


Fig. 1. Scheme of 4-by-4 sensor network, and the corresponding snapshots obtained for a linear cloud edge advance considering $T_s = 1$ s.

of the square. However, v_{max} can be measured in all cases, and therefore it will be considered the upper detection limit of the network.

In this study we considered monitoring networks with n ranging from 3 to 10, therefore implying networks of 9 to 100 sensors. The side length is constrained to the range $10m \leq L \leq 100m$ according to the typical sizes of building rooftops where small-scale PV systems are installed. Finally, we have considered an upper speed limit of 30 m/s¹, what implies sampling periods from 0.3 to 3.3 s for the considered network layouts.

2.2. The small-scale context

The estimation of the CMV from measurements of a sensor network is not a direct task and the associated uncertainty depends not only on the spatial and temporal resolution, but also on the inference methodology. Fig. 1 helps to illustrate the problem in the context of the snapshots by assuming linear cloud edges, a simplification that facilitates the analysis in sensor arrays. Despite $\vec{v} = (10, 10)$ m/s, the apparent velocity associated to two subsequent snapshots is $\vec{v}_a = (0, 10)$ m/s. This is because, in absence of features that allows tracing unequivocally the cloud trajectory, the motion seems to be orthogonal to the cloud's edge². Concretely, the apparent velocity can be defined as the projection of \vec{v} onto the normal to the cloud's edge, as explained in detail in (Lappalainen and Valkealahti, Nov 2016). The result is that small-scale sensor networks do not provide direct representations of the cloud velocity, thereby requiring an inference process to estimate the real CMV. Hence, besides the sensor network, the inference process is another key factor in the CMV estimation as it introduces its particular errors.

The absence of clear features is a common element in data provided by small-scale irradiance sensor networks. Moreover, as shown in the sequences of snapshots included in Espinosa-Gavira et al. (2018), the cloud edges appear like a gradation of irradiance in the range of meters and the spatial sampling introduce a noisy component in the provided snapshots. The synthetic framework explained in SubSection 2.3 and represented in Fig. 2 also helps to illustrate this point. It can be observed how the final representation of a cloud edge captured by a small-scale sensor network is a noisy gradation of irradiance values where features are difficult to be recognized and detected in subsequent snapshots. These characteristics introduce specific problems in the estimation of CMV that penalize the application of methods based on cloud image processing. This issue is analysed in depth in SubSection 4.1.

Finally, the limited budget is another important constraint associated with the small-scale irradiance monitoring networks. Mazzola et al. (2017) stressed that the cost of the instrumentation and forecasting system must be in relation with the cost of the PV systems, constituting an important constraint for smaller systems. Thus, the specifications of the monitoring systems of advanced scientific infrastructures or top-level solar research projects must be ruled out. In other words, the forecasting solutions for small-scale PV systems should consider low design requirements for the monitoring, computation and communication devices. In this sense, the use of all-sky cameras or satellite imagery would exceed the complexity and cost limits. On the other hand, only basic information can be demanded from these monitoring systems, excluding estimations from multiple cloud layers, early detection of sudden changes of flow, or accurate estimations for extreme cloud speeds.

2.3. Necessity and generation of synthetic data

Testing methods for the estimation of CMV with real data has an important drawback: the true CMV remains unknown. Thus, validations are performed based on other CMV estimations obtained from images (Kuhn et al., Oct 2018), radiosondes (Bosch et al., 2013), or measured wind velocities (Smithpeter, 2018). We have implemented a synthetic framework in order to generate time series for irradiance monitoring networks according to a given (known) CMV. We have used the fractal cloud model described by Lohmann et al. (2017) to simulate irradiance fields of 8192 m x 8192 m with a resolution of 1 m (Fig. 2 left). This model is based on the square-diamond algorithm which is widely used for terrain generation in computer graphics. The starting point is a square matrix with random values at the corners. In each iteration, the algorithm gives values to the central pixels by adding the arithmetic mean of the corners to a Gaussian variable whose standard deviation depends on the chosen fractal dimension, so that smaller squares (or diamonds in the odd iterations) are generated. (The process is repeated until the matrix is filled.) Once the matrix is filled, a specific function is applied to model the cloud transitions and, eventually, the resulting values are converted to clear-sky indexes.

Two modifications have been made on the model proposed by Lohmann et al. (2017):

1. In Lohmann et al. (2017), clouds are generated with a fractal dimension of 1.5 as an intermediate value between the value of 1.6 observed at scales of tens of kilometers with satellite imagery, and the value of 1.4 observed at scales of tens of meters with all-sky-cameras. Since the present study is focused on the latter spatial range, a fractal dimension of 1.4 is used in the generation of clouds. The consequence is that the resulting clouds should be more fractioned at larger scales. But, on the contrary, they provide a better representation of the smaller features associated with irradiance transitions.
2. The result of Lohmann et al. (2017) is a clear-sky index field. In order to translate it to an irradiance field, we assumed that a clear sky-index of 1 is associated with an irradiance of 800 W/m². Since the resulting clear-sky index ranges from 0.2 to 1.2, irradiances from 160 W/m² to 960 W/m² are obtained.

The cloud motion is simulated by displacing the obtained irradiance field over a monitoring domain according to the given CMV and sampling period (see domains in Fig. 2). Finally, the snapshots are generated by selecting the irradiance values corresponding to the sensors' position in each displacement (see snapshots in Fig. 2). This can be also interpreted as a generation of synchronized series for each sensor. Since irradiance data are generated with a resolution of 1 m, the displacements including decimal values may not coincide with the positions of the irradiance grid. In these cases, the values for each sensor are calculated as the inverse distance weighted average of the four closest values, in other words, the irradiance details below meter are not reproduced.

Obviously, this synthetic framework provides only an approximation of real-life irradiance fields. For instance, the procedure does not reproduce cloud formation/dissipation processes, sudden changes of flow, or velocity variations over the monitoring domain. The effects of multiple cloud layers are also omitted. However, it can be considered that the limited size of the monitored area minimizes possible variations of cloud velocity over the domain. The domain dimension also limits the effects of formation/dissipation processes, reducing them to slight random variations of irradiance. Thus, in some sense, the random component introduced in the snapshots by the fractal noise and spatial sampling provides a certain representation of these processes (Fig. 2). By implementing minor modifications, the proposed synthetic framework would be able to simulate the effects of multiple cloud layers or sudden changes of flow. But, as explained in SubSection 2.2, these

¹ Based on 15 months of observations, Lappalainen and Valkealahti (2016) reported that cloud shadow speeds were mostly below 30 m/s.

² This is known as ‘aperture problem’ in computer vision

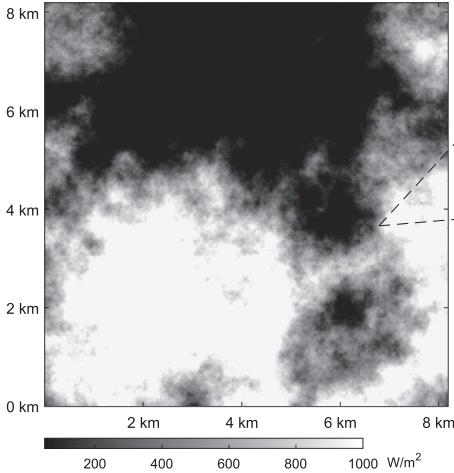


Fig. 2. Generation of snapshots. Left graph: irradiance map derived from the fractal cloud model. Right upper graphs: zoom and evolution of the monitored domains for a given cloud motion vector (represented in the center of the graphs), the position of the sensors is indicated with ‘x’. Right lower graphs: snapshots provided by the 4-by-4 array of sensors.

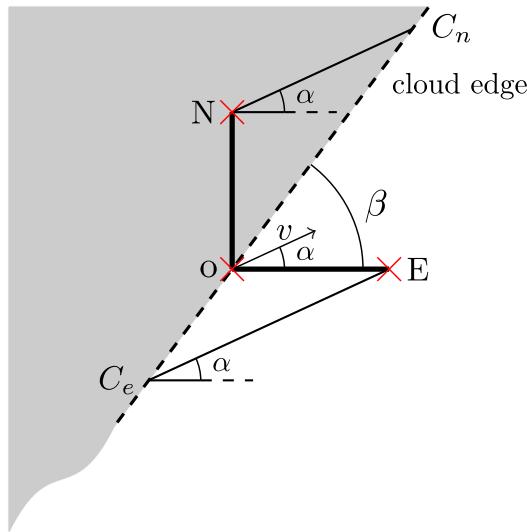


Fig. 3. Linear cloud edge passing over the triplet of sensors. β : Angle between cloud edge and \overline{OE} axis. α : Angle between CMV and \overline{OE} axis. C_e and C_n : cloud edge points that pass over sensor N and E respectively. This figure is inspired in Bosch et al. (2013).

phenomena entail a complexity that exceeds the capacity of small-scale networks. Furthermore, the obtained sequences of snapshots would be incompatible with the conditions for the application of the benchmark methods, as described in the following section.

3. Reference methods

3.1. The Most Correlated Pair (MCP) method

This method assumes that the irradiance measurements of a pair of sensors aligned with a given CMV will be highly correlated but showing a certain time lag (t_{ab}). This lag can be estimated by means of cross-correlation between both irradiance series. Hence, the cloud motion speed can be calculated with the following expression:

$$v = D_{ab}/t_{ab}, \quad (1)$$

where D_{ab} denotes the distance between both sensors. The estimated cloud motion direction is given by the line defined by the two concerned sensors. The output directions are thereby limited by the couples of sensors that can be associated within the network. The upper speed detection limit is determined by the product sampling rate and distance between the most correlated pair of sensors. The method is defined for

two different configurations. One of them was presented in (Bosch et al., 2013), using eight sensor grouped in seven pairs and sharing the central sensor, arranged in a semi-circumference layout. The second configuration was described in (Bosch and Kleissl, 2013), using all possible inverter combinations of a power plant, by assuming that the inverters’ power output is strictly correlated with the irradiance level.

The MCP method is affected by noise produced by the inaccuracies in the determination of time lags, and raw results needs to be quality controlled in the following aspects: (i) CMVs with low correlation coefficient are excluded and (ii) unphysical speeds and direction outliers are discarded.

3.2. The Linear Cloud Edge (LCE) method

The Linear Cloud Edge method works with a triplet of sensors, assuming linear edges of the observed part of the clouds. It was firstly formulated for a right angle sensors layout (Bosch et al., 2013) and later generalized for non-right angle configurations (Bosch and Kleissl, 2013). In this case, the CMV cannot be simply determined from time lags between sensors. Thus, the estimation requires a more complex calculation based on the detection of several common maxima and minima within the three irradiance series (hereinafter expressed by the term ‘cloud pass’).

Fig. 3 represents a generic cloud pass with linear edge over a 90 degree sensor layout. Each cloud pass gives lags for the North and East sensors relative to O sensor, denoted by t_{on} and t_{oe} respectively. But the information provided by one cloud pass is not enough to calculate the real CMV due to the ambiguity introduced by the apparent velocity, already commented in SubSection 2.2. In other words, the result of this calculation is a family of possible CMVs, all of them sharing the same apparent velocity. Hence a second cloud pass with different cloud edge angle is required to obtain a second family of possible CMVs. Only the real CMV is compatible with both families. By assigning indices 1 and 2 for the first and second cloud pass, the cloud motion direction can be determined as:

$$\alpha = \arctan\left(-\frac{t_{oe2} - t_{oe1}}{t_{on2} - t_{on1}}\right), \quad (2)$$

where α is the cloud direction. Once alpha is obtained, the cloud shadow speed (v) can be estimated as follows:

$$t_{on1}\sin(\alpha) + t_{oe1}\cos(\alpha) = D/v, \quad (3)$$

where D is the distance between North and O sensors and East and O sensors.

The method gives a noisy output which can leads to unphysical CMV, therefore requiring a quality control process:

1. $v_i < 50 \text{ mm/s}$.
2. $|v_i - \bar{v}| < 2v_\sigma$.
3. $|\alpha_i - \bar{\alpha}| < 2\alpha_\sigma$.

where v_i and α_i represent the CMV modulus and direction at the instant i , and \bar{v} and $\bar{\alpha}$ denote the mean speed and direction considering the last minutes, and v_σ and α_σ represent the standard deviation of speed and direction in the concerned period.

In this work, the LCE method has been implemented following the procedure described in Bosch et al. (2013), with two modifications: (i) the time window for the search of global maxima is adapted to the sampling rate and the distance between sensors in order to capture minimum speeds of 3 m/s, (ii) the quality control is based on measurement of 5 min. The unphysical cloud speeds has also been considered as outliers applying the quality control.

4. Proposal of a new method

The irradiance field snapshots provided by a gridded sensor network can be interpreted as images with each pixel representing the measurement of the corresponding sensor. The CCM has been widely applied to all-sky and satellite imagery in the estimation of the CMV. This makes the CCM a good candidate for inferring the CMV from irradiance snapshots. However, the application of the CCM in the smaller scales presents some drawbacks that in turn suggests some modifications of the method. The implementation of these modifications finally results in a new method specifically adapted to the concerned problem. The drawbacks, modifications, and final proposition of the new method are detailed in the following subsections.

4.1. Discussion of the CCM

As explained in Section 1, the CCM is based on finding parts (or templates) of a previous image into an updated one to detect displacements. The observed displacements and time difference between both images are used to calculate the CMV. The cross-correlation coefficient gives a measure of similarity between the template and the portion of the updated image selected for comparison, by means of a convolution of their corresponding values. Despite its applicability in

all-sky and satellite imagery, the application of the CCM to irradiance snapshots from small-scale monitoring networks is limited by the following aspects:

- The size of the image: All-sky images contains millions of pixels allowing the CCM to process templates of hundreds of pixels. Furthermore, the template displacements can be constrained to those in which the boundaries of the target image are not crossed by the template. This constrain assures that the cross-correlation coefficients are calculated with a constant number of pixels in all cases, only excluding a relatively low number of displacements. In the case of the sensor networks, the snapshots are in the range of tens of pixels. The templates are consequently composed of few pixels and the displacements are very reduced in order not to cross the image boundaries.
- The size of the monitored area: all-sky cameras provide a wide visual field which facilitates the detection of cloud features to be recognized in subsequent images. In the case of sensor networks, the monitored area is very limited and the snapshots do not exhibit features to be unambiguously located in consecutive images. The problem of apparent velocities (aperture issue) is also magnified by the small size of the monitored area.
- The spatial sampling: All-sky images provide an approximately continuous map of the clouds. However, the sensor networks sample the irradiance field in a discretized way. Thus, cloud features measured by a sensor (for instance a high-irradiance spot) may not be captured by the resting sensors in the consecutive snapshot. Moreover, the consecutive snapshot could include another high-irradiance spot unobserved in the previous snapshot. The CCM can be driven by the apparent displacement of the spot producing erroneous results. In other words, the noise introduced by the spatial sampling can mislead the CCM inference process.
- The cross-correlation coefficient: The cross-correlation coefficient gives a measure of the similarity between the template and the target image: the higher the cross-correlation coefficient, the higher the similarity. The inherent operation is a convolution between the corresponding values of the template and target images. Although the coefficients based on the convolution have a good performance with images once they are processed, they do not perform well with

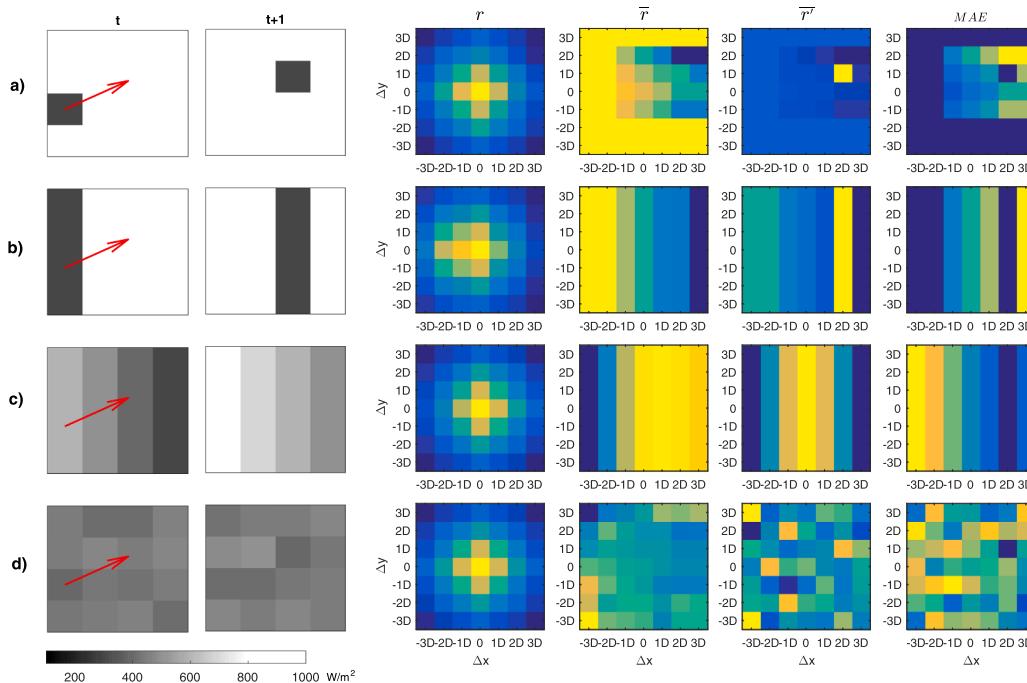


Fig. 4. The two left columns represent the irradiance snapshots at time t and $t + 1$ in four theoretical situations with a common $\text{CMV} = (2\text{D}, 1\text{D}) \text{ m/s}$ represented by a red arrow. The resting columns show the displacement diagrams obtained with the similarity measures indicated in the top of the column. The values in each diagram are dependant on the concerned coefficient and snapshots. The best match displacement is associated with the highest value of r , \bar{r} , and \bar{r}' , and with the lowest value of MAE. Hence, only the relative values are significant and therefore the colour bars are omitted for clarity purposes.

the scarce information of the snapshots, as explained in detail in the following section.

4.2. CCM formulations in the small-scale context

As explained above, the limited number of pixels penalizes the application of the CCM with the irradiance snapshots since they constrain the size of the templates and the possible displacements. These problems can be mitigated by implementing other formulations of the CCM; for instance, by using the whole snapshot (not a portion) as the reference template and allowing crossing boundaries. In these conditions and considering n-by-n snapshots, 2n-1 displacements are possible in each axis. For illustration, Fig. 4 shows four cases of two consecutive 4-by-4 snapshots with similar CMV ($V_x = 2D$, $V_y = 1D$), and the associated diagrams representing the cross-correlation coefficients obtained for all possible displacements. Note that the displacements reduce the number of overlapped pixels over which the coefficient is computed, ranging from n^2 pixels for a null displacement to one pixel for the maximum displacements in both axis. The calculation of the cross-correlation coefficient r can be summarized with this formula:

$$r = \frac{1}{N} \sum_{k=1}^N S'_t(k) \cdot S'_{t+T_s}(k), \quad (4)$$

where and S'_{t+T_s} denotes the overlapped sub-matrices of the snapshots S_t and S_{t+T_s} for a determined displacement $\Delta x \Delta y$, N the number of overlapped elements, and k a generic index that spans the overlapped elements.

The first problem with the modifications of the CCM is that the r values obtained this way are biased because they are computed with a different number of overlapped pixels and, consequently, with a different number of elements in the convolution. The column of graphs ' r ' shows the results associated with this coefficient. Regardless the cloud features represented in the snapshots, the diagrams show a similar structure: the highest r value is associated to a displacement of $\Delta x = 0$, $\Delta y = 0$ (the center of the diagram) whereas the lowest values are associated with the maximum displacements (the corners of the diagram). This is related to the number of elements involved in the convolution, which is 16 (the whole snapshot) for $\Delta x = 0$, $\Delta y = 0$ and decreases as the displacements increase. As a result, the effect of the

number of pixels computed in the each displacement hides the similarity measure provided by the coefficient r .

To overcome this problem, r can be divided by the number of elements of the convolution (the number of overlapped pixels), resulting in a normalized cross-correlation coefficient. The resulting coefficient \bar{r} is defined by the following expression:

$$\bar{r} = \frac{1}{N} \sum_{k=1}^N S'_t(k) \cdot S'_{t+T_s}(k). \quad (5)$$

The results including this correction are shown in column ' \bar{r} '. Indeed, the border effects are not present in these diagrams, but the coefficient seems to not be appropriated for the detection of cloud motion. This is clearly visible in the upper graph (case a). Despite the displacement of the cloud shadow between the snapshots seems evident, the highest \bar{r} values are associated with other displacements, being some of them in the opposite direction. The reason is that these values are obtained for displacements in which the pixel with the lowest value of irradiance is excluded (out of the borders of the overlapped area), and thus the convolution is calculated only with maximum values. The results in the resting cases are also affected, in some degree, by this problem.

Improved results can be achieved by subtracting the mean value of the snapshot so that positive and negative values are introduced in the convolution. The resulting coefficient \bar{r}' can be interpreted as a zero-mean normalized cross-correlation coefficient that is defined by the following expression:

$$\bar{r}' = \frac{1}{N} \sum_{k=1}^N (S'_t(k) - \bar{S}'_t) \cdot (S'_{t+T_s}(k) - \bar{S}'_{t+T_s}). \quad (6)$$

The results are shown in the respective column in Fig. 4. In the case (a), the methodology unambiguously assigns the maximum \bar{r}' value to a displacement $\Delta x = 2D$, $\Delta y = 1D$, which coincides with the intrinsic CMV and the time step of 1 s. In the case (b), the methodology outputs a band of maximum values for all possible displacements with $\Delta x = 2D$. In effect, this is the apparent velocity for a linear cloud edge and the band represents all possible solutions for this apparent velocity. In both cases, the proposed modifications of the CCM work efficiently. However in the cases (c) and (d), which are closer to realistic cases, the methodology is not capable to provide useful information. The case (c) shows

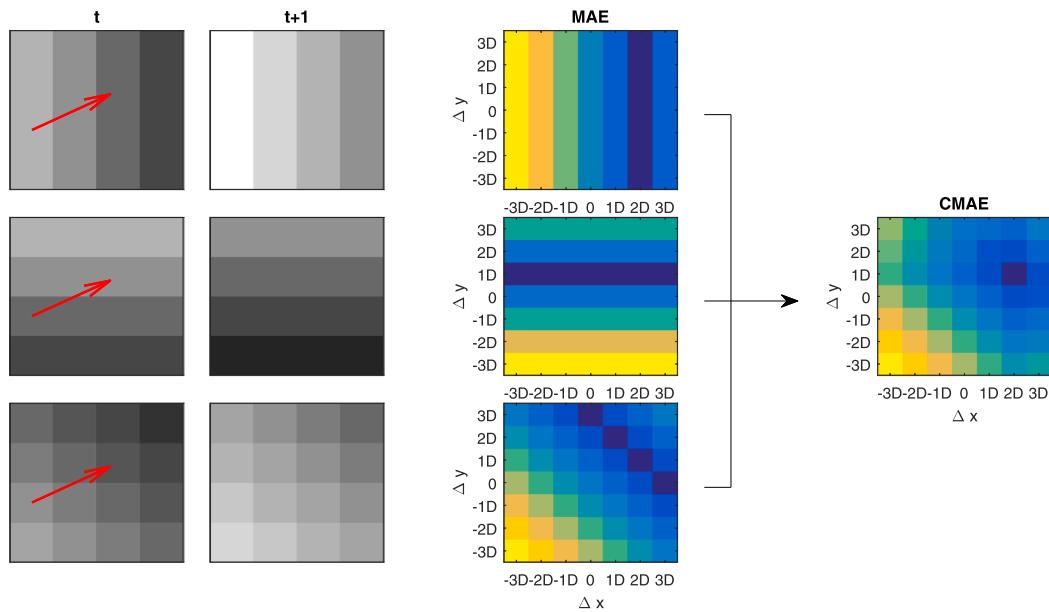


Fig. 5. Irradiance snapshots at time t and $t + 1$ in three theoretical situations with a common CMV = (2D, 1D) m/s represented by a red arrow and the corresponding displacement MAE diagrams. The right graph represents the cumulative MAE diagram obtained by the aggregation of the three MAE diagrams (CMAE diagram). In the displacement diagrams only the relative values are significant.

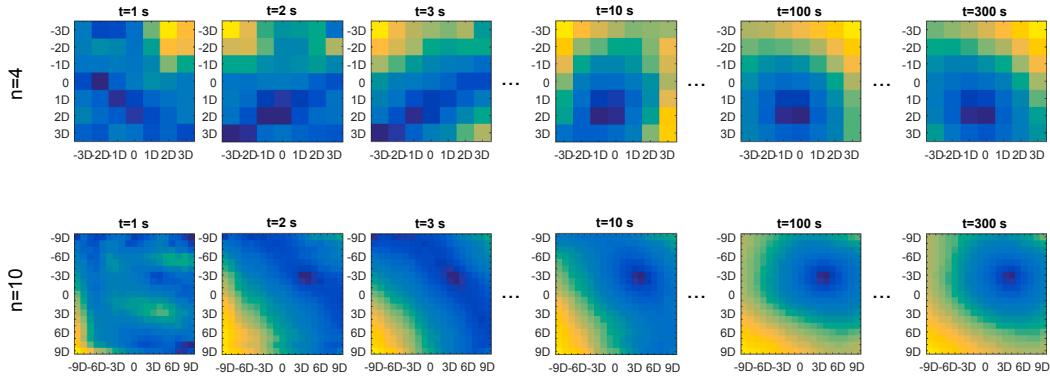


Fig. 6. Evolution of CMAE diagrams during 300 s. The upper row is associated with a 4-by-4 network with $D = 10$ m, $T_s = 1$, and an input CMV = $(-5, -17)$ m/s. The method outputs an estimated CMV = $(-6.28, -17.11)$ m/s. The lower row is associated with a 10-by-10 network with $D = 3.3$ m, $T_s = 1$, and an input CMV = $(12, 9)$ m/s. The method outputs an estimated CMV = $(12.18, 8.99)$ m/s.

the advance of a gradation of irradiance, that is a good representation of the real cloud edges on the scale of meters. In this case, the subtraction of the mean value hides the difference between both snapshots, and the method outputs a maximum band on $\Delta x = 0$, erroneously indicating that the compatible displacements are only possible in the y-axis. The case (d) represents the advance of an irradiance field with slight random variations, which is also close to what is observed in real cases. The highest \bar{r} values are randomly distributed over the diagram and none of them coincide with the real displacement. Again the convolution favors those displacements which put together high values of both snapshots (in this case also accounting for sign) instead of those with similar values.

As commented, the normalized cross-correlation coefficient and the zero-mean normalized coefficients are widely used in computer vision applications (Liu et al., 2019).

4.3. The cumulative mean absolute error (CMAE) method

Even if they entail a significant improvement, the proposed formulations of the CCM are limited by the convolution, which is not able to provide reliable similarity measures under the particular conditions of small-scale irradiance sensor networks. The convolution can be replaced by the mean absolute error (MAE), resulting in the following similarity measure:

$$\text{MAE} = \frac{1}{N} \sum_{k=1}^N |S'_t(k) - S'_{t+T_s}(k)|. \quad (7)$$

Consequently, the search of the maximum cross-correlation coefficient can be replaced by the search of the minimum MAE. The column ‘MAE’ in Fig. 4 shows the diagrams obtained with this modification. In the case (a), the diagram shows a minimum value for all those displacements that excludes the pixel with the lowest value of irradiance. This effect is analogous to the one observed for the \bar{r} coefficient. But unlike \bar{r} , the MAE also assigns a minimum value to the real displacement $\Delta x = 2D$, $\Delta y = 1D$. The case (b) is analogous: the minimum MAE is associated with the displacements in which the low irradiance band is excluded, but also with the band of displacements $\Delta x = 2D$ according to the real apparent velocity. In these simplified cases, the MAE performs better than \bar{r} , but not surpassing \bar{r} which unambiguously determines the displacement (or band of displacements) compatible with the movement captured in the snapshots. The MAE demonstrates its benefits in the more realistic cases (c) and (d), in which neither \bar{r} nor \bar{r} provided useful information. In the case (c), the MAE diagram shows a band of minimum values in $\Delta x = 2D$, which indicates the family of displacements that are compatible with the apparent velocity. In the noisy framework of the case (d) the minimum MAE clearly indicates the real displacement. It must be stressed that real snapshots are a mixture

of different proportions between cases (c) and (d), therefore the MAE provide the best similarity measure in this context.

The MAE do not solve the ambiguity problems of the apparent velocity. However, the aggregation of MAE diagrams at different time steps produces a graphical solution for this problem, as shown in Fig. 5. The snapshots show three cloud edge advances with a similar CMV. Despite this, the advance of the clouds seems to be different depending on the orientation of the cloud edge; in other words, they exhibit a different apparent velocity. The MAE diagram shows, in each case, the family (or band) of displacements compatible with the apparent velocity, which necessarily includes the real displacement. The CMAE diagrams shows how the aggregation of bands from different cloud edge passes³ unambiguously determines the displacement common to all bands, i.e. the only displacement that explains all the apparent velocities. Besides the absence of convolution products, this aspect constitutes the main difference between the CMAE and CCM procedures. However, in some sense, the same concept is applied in the LCE method, which requires the time lags from two cloud edge passes to determine the CMV, but in the proposed method, multiple events (not necessarily involving cloud edges) can be aggregated. Note that it is assumed a constant CMV during the period as stated in preliminary considerations.

Fig. 6 shows the evolution of the CMAE diagram during 300 s according to two sequences of snapshots generated with fractal clouds. In both cases, the first step provided ambiguous information of the clouds displacements. This is due to the misleading effects related to apparent velocities or discrete sampling noise that hide the inherent cloud motion. Due to their random nature, these misleading effects can be compensated by aggregating successive results in the diagrams. Thus, in subsequent steps, the diagrams become clearer revealing the displacements that better explained the irradiance variations observed during the entire period, i.e., those of the lowest CMAE values. Similar procedures have been applied to the Lucas-Kanade method in order to reduce errors in optical flow estimations (Lim et al., Aug 2005).

In Fig. 5 we considered simplistic cloud shadows and a CMV coincident with a specific displacement in the diagram. Thus, the minimum error value was clearly associated with the corresponding pixel. The more realistic examples of Fig. 6 present minimum values distributed in adjacent pixels, indicating that the inherent displacement is intermediate among those pixels. In this conditions, the CMV can be inferred as a centroid. Empirically, we obtained the best CMV estimations by an inverse-weighted interpolation of the three displacements with lowest CMAE value:

³ Assuming that they occurred in a lapse of time in which the CMV can be considered constant.

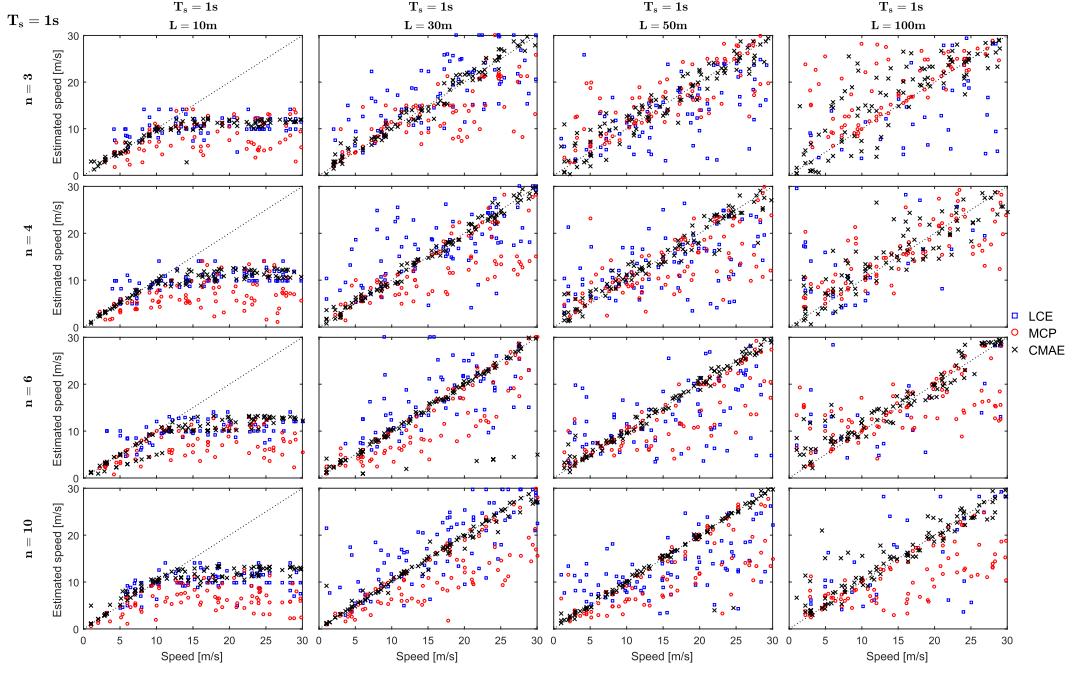


Fig. 7. Speed results for the different configurations with $T_s = 1$ s.

$$\begin{pmatrix} V_x, V_y \end{pmatrix} = \frac{1}{T_s} \sum_{i=1}^3 w_i \cdot \begin{pmatrix} \Delta_i x, \Delta_i y \end{pmatrix}, \quad (8)$$

$$w_i = \frac{\frac{1}{CMAE_i}}{\sum_{j=1}^3 \frac{1}{CMAE_j}}, \quad (9)$$

where i and j are indices that covers the three displacements with lowest CMAE value, w_i represents the contribution of the i-th displacement to the cloud motion vector, and $CMAE_i$ denotes the cumulative error of the i-th displacement. Note that the estimation accuracy is not limited by the spatial or temporal resolution of the monitoring network, because the weighted combination of the three considered

displacements can produce intermediate results.

5. Results

A series of tests have been performed considering different network layouts by varying the number of sensors, sizes of the monitored area, and sampling periods. Concretely, configurations of 9 ($n = 3$), 16 ($n = 4$), 36 ($n = 6$) and 100 ($n = 10$) sensors with side lengths of 10, 30, 50 and 100 m were chosen. The sampling periods were adapted according to the objective of each test as detailed below. Once a configuration is chosen, 100 CMVs were randomly generated with speeds ranging from 0 to 30 m/s and directions ranging from 0 to 360°. For

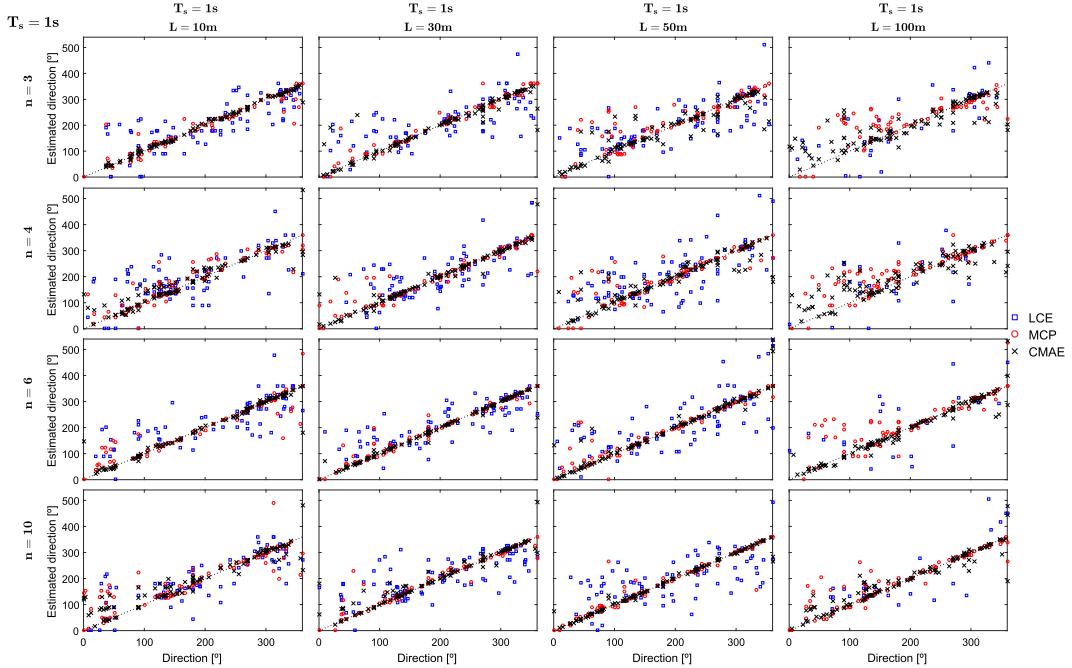


Fig. 8. Direction results for the different configurations with $T_s = 1$ s.

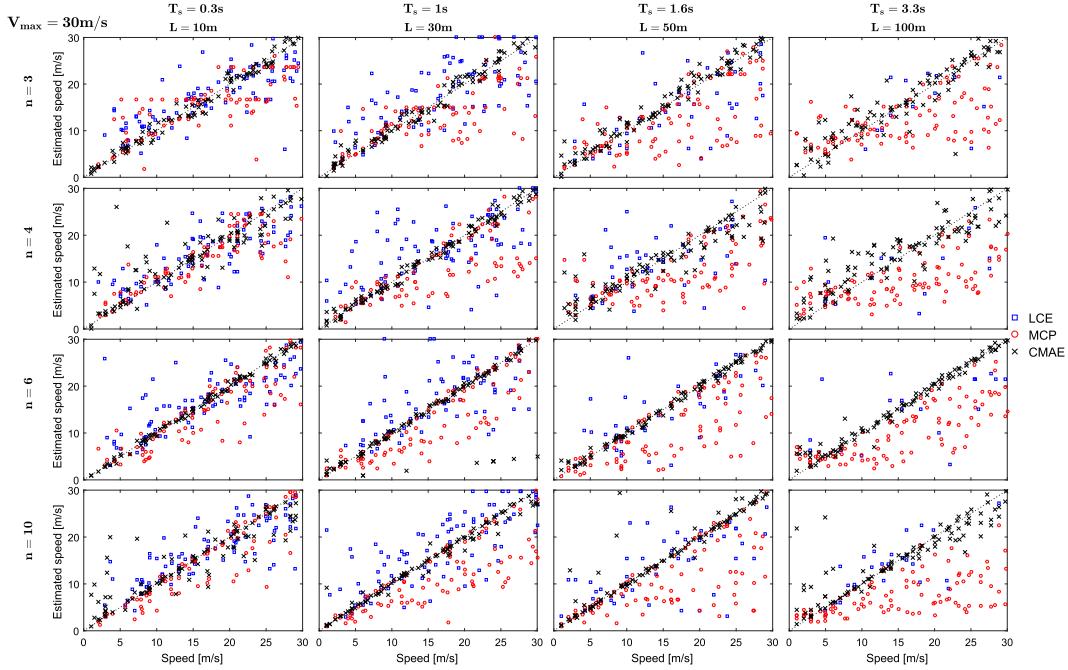


Fig. 9. Speed results for the testes configurations considering $V_{max} = 30$ m/s.

each CMV, a sequence of snapshots covering 300 s were simulated according to the procedure described in SubSection 2.3. The simulated sequences were forced to include more than 150 s of irradiance variability in order to assure enough cloud passing information to perform the estimations. The three methods (MCP, LCE and CMAE) were applied to each sequence with known CMV. The results of these tests are represented in Figs. 7–9, and quantified by means of error statistics in Appendix A.

Firstly, a sampling period of 1 s was fixed to test the methods in relation with the different network configurations (Figs. 7 and 8). The first overall conclusion is that the LCE method exhibits the worst performance in all cases, with the exception of the network with $n = 3$ and $L = 100$ in which all the methods are seriously affected by the low density of measurement points in the estimation of cloud shadow speeds. Another general conclusion is that directions are easier to estimate. The MCP and CMAE methods are comparable in this aspect, providing accurate estimations of cloud directions although the CMAE was superior for larger areas $L = 100$ m. Focusing on the speed results (Fig. 7), the first noticeable feature is the upper speed limit observed in the graphs associated with $L = 10$ m. This effect is not related to the methods' inability to estimate the cloud shadow speeds, but to the constraints of the network specifications. The sampling period of 1 s and the side length of 10 m determine a maximum measurable speed of 10 m/s ($10\sqrt{2}$ for diagonal motion). Consequently, the results for input speeds higher than 10 m/s are similarly biased for all methods. The remaining configurations do not present this limitation, being able to measure cloud shadow speeds of, at least, 30 m/s. In the graphs and

tables, the CMAE shows the best performance in all cases, specially in those networks with a high spatial density of sensors. Thus, the CMAE method achieved a root mean square error (RMSE) value of 1.4 m/s with the highest density network ($n = 10$, $L = 30$ m, 1 sensor per 9.0 m^2), while the MCP and LCE obtained 6.5 m/s, and 5.6 m/s, respectively. On the other hand, the RMSE values for the lowest density network ($n = 3$, $L = 100$ m, 1 sensor per 1111.1 m^2) were 5.7 m/s, 8.4 m/s, and 9.2 m/s for the CMAE, MCP and LCE, respectively. The two intermediate cases help to complete the scenario. The network $n = 6$, $L = 50$ m (1 sensor per 69.4 m^2) provided RMSE values of 1.2 m/s, 6.2 m/s, and 8.3 m/s; and the network $n = 4$, $L = 30$ m (1 sensor per 156.3 m^2) provided values of 3.2 m/s, 7.3 m/s, and 6.7 m/s for the CMAE, LCE and MCP, respectively. The reader is referred to the Appendix A to obtain a complete statistical description of these graphs, including mean errors (ME) and mean absolute percentage errors (MAPE) organized in bins to reflect the dependencies between results and input speeds. In this sense, it can be checked how one of the strengths of the CMAE method is its low bias, generally lower than 1 m/s, and non-dependent on the input speed value. The MCP is the most biased method, generally underestimating the speed in high density networks, and also being highly dependent on the input speed. The LCE presents the overall worst performance, being clearly penalized by the MAPE values.

In a second experiment, we tested the same configurations adapting the sampling rate to a maximum speed limit of 30 m/s. Thus, in the case of networks with $L = 10$ m, which in the previous tests were limited to 10 m/s, the sampling period was decreased to 0.3 s. On the contrary,

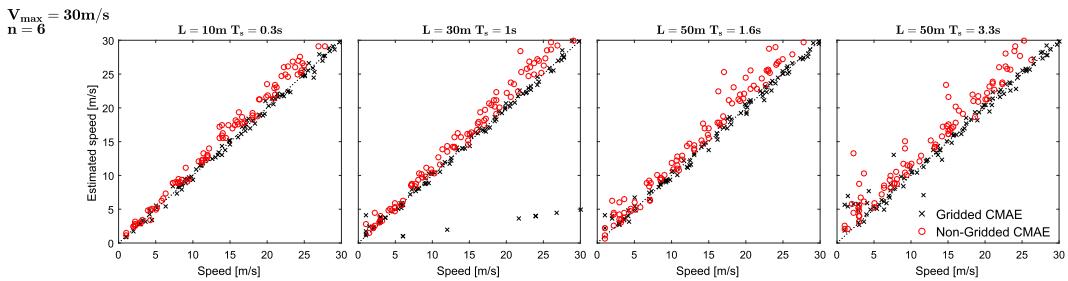


Fig. 10. Comparison of speed results between gridded and non-gridded sensor networks.

the sampling rate of the networks with $L = 100$ m was increased to 3.3 s. These modifications are relevant for real applications: In the first case, because by decreasing the sampling period, the networks become usable for very-short-term PV prediction purposes since they can measure in an acceptable range of speeds; and in the second case, because the amount of data generated by the network is reduced while maintaining an appropriated measurement speed range. The amount of data is an important issue in the management of sensor networks, specially if wireless communications technologies are involved.

The direction graphs have been omitted as they did not provided additional information with respect to the Fig. 8. The speed results are represented in Fig. 9. The associated statistics (see Appendix A) are aligned with the previous results, with the CMAE method being superior but showing more dispersion than expected. The results of the networks with $L = 30$ m are obviously similar to the ones in Fig. 7 as the sampling period is also 1 s. For larger areas, the CMAE shows an overall improvement regarding the previous experiment whereas the LCE and MCP methods perform worse. This is a significant result that seems counterintuitive. It can be explained considering that the lack of time resolution is detrimental for the accurate determination of lags which is the basis of the cloud motion estimation in LCE and MCP methods. However, the CMAE method is based on the comparison of snapshots. Hence, shorter sampling periods entail higher similarity between consecutive snapshots and, consequently, a diminished ‘perception’ of the cloud displacements. This analysis is also supported by the above commented dispersion of CMAE results observed in the networks with $L = 10$ m. Despite these networks involve higher densities of measurement points, and thereby they may improve the estimations obtained for $L = 30$ m, the results do not reflect this advantage. On the contrary, the results of the MCP and LCE methods were improved benefited by the precision in the determination of time lags. Finally, it is also remarkable that the LCE method have problems to output results as the sampling periods increase. Concretely, the LCE method only provided results in 20% of cases for sampling periods of 3.3 s, and in 47% of cases for sampling periods of 1.6 s. This is due to the decrease of points in the series which makes difficult the fulfilment of the calculation and quality control conditions. In this sense, the CMAE is the most robust method since it provided estimations in 100% of cases thanks to the absence of strict conditions for calculation and quality control.

6. Generalization to non-gridded sensor networks

The gridded distribution of sensors is not always feasible due to the network layout is frequently constrained by the presence of obstacles or the shape of the monitored area. Since non-gridded distribution do not provide snapshots directly, the CMAE method would have limited application in real cases. In this sense, the kriging method can be used to generate gridded irradiance values at unobserved locations from a set of non-gridded observations (Aryaputera et al., 2015; Jamaly and Kleissl, 2018). The gridded irradiance values generated this way can be

considered snapshots, and the CMAE method can be similarly applied on them.

The aim of this section is not to make a thorough analysis of the kriging method application for non-gridded, small-scale sensor networks, but to certify its validity in the generation of snapshots to be used by the CMAE method. Then, a deeper study should be conducted as part of future work. In the present framework, the snapshots were generated by ordinary kriging with spherical variogram as described by Monger et al. (2016), which is a common and simple implementation of this method. It is worth mentioning that this approach provides a spatial interpolation of measurements and thereby the snapshots are based on estimates instead of real observations. This introduces additional uncertainty in the CMV estimation.

The procedure was similar to the one described along the latter study with two differences:

- Random distribution of sensors: the size of the monitored area and the number of sensors were similar in the gridded and the non-gridded configurations. For instance the network $n = 6$, $L = 50$ m covered an area of 2500 m^2 with 36 sensors in both cases. The difference is that, in the non-gridded case, the position of the sensors was generated by a random process for each simulation of 300 s, thereby assuring that the overall results were not affected by a particular layout of the network.
- Generations of snapshots: the series of 300 s were generated for each sensor’s position according to the procedure described in SubSection 2.3. Then, the snapshots were generated by applying the kriging method with the spherical variogram fitted to the observations in each time step, in order to obtain grids of interpolated values. The output positions coincided with the positions of the sensors of the corresponding gridded network. Thus, the obtained snapshots have similar resolution and dimensions in both the gridded and non-gridded cases.

In Figs. 10 and 11, the results from $n = 6$ gridded and non-gridded networks are compared. Regarding directions, they have a similar performance, with very accurate estimations for smaller areas and an increased dispersion for larger ones. However, the speed values from non-gridded networks are biased, resulting in an overestimation proportional to the input speed, and slightly affected by the size of the monitored area. This indicates that the uncertainty introduced by the interpolation is translated to the speed estimations. The statistics from these graphs can be also consulted in Appendix A.

7. Summary and conclusions

The present paper proposed a novel method for cloud motion vector estimation adapted to small-scale irradiance sensor networks. The method is defined in the framework of the gridded sensor networks, and subsequently, generalized for non-gridded networks. The method is tested by using synthetic irradiance fields obtained from a fractal cloud

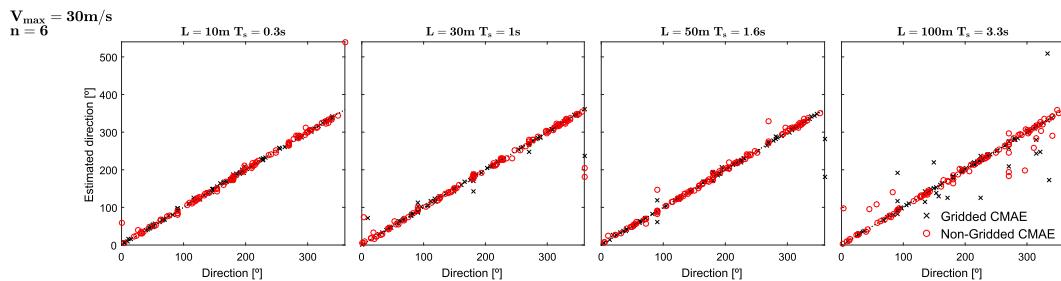


Fig. 11. Comparison of direction results between gridded and non-gridded sensor networks.

model in order to generate clouds displacements with arbitrary cloud motion vectors. Thus, the tests can be performed with known cloud motion vectors, what is a novelty in this sort of studies. A variety of networks have been analysed with number of sensors ranging from 9 to 100, monitored areas from 100 to 10000 m², and sampling periods from 0.3 to 3.3 s. The Linear Cloud Edge and the Most Correlated Pair methods are used for benchmarking purposes.

The proposed method is derived from the cross-correlation method used in cloud motion estimation from satellite and all-sky imagery. The problems of the cross-correlation method implementation in the context of small-scale irradiance networks are discussed in detail. This discussions eventually led to the definition of a new method (the cumulative mean absolute error method), which is characterized by the following aspects:

- The use the whole snapshot/image as a template.
- The acceptance of crossing borders for the comparison of snapshots.
- The use of the mean absolute error as a measure of similarity avoiding the convolution inherent to cross-correlation coefficients.
- The aggregation of multiple solutions to solve the problem of apparent velocities and diminish the estimation uncertainty.

The tests demonstrate the superiority of the proposed method, specially in the determination of speeds, obtaining the best RMSE values in 90% of tested configurations, and presenting a reduction of the RMSE errors of 50%-90% in a 75% of the cases respect the benchmark methods. The results also show that the CMAE estimations based on non-gridded networks were more accurate than the ones obtained by the LCE and MCP methods based on gridded networks. This indicates the validity and potential of the kriging method in generating snapshots to be processed by the CMAE method. In this sense, the described procedure demonstrates its applicability to real-world networks which generally have irregular layouts forced by the presence of obstacles, building or urban constrains. Additionally, the CMAE method also entails the following strengths:

- Robustness: The method provided estimations in cases that the benchmark methods did not work. The absence of calculation or quality control conditions makes the method capable to work in a wide range of situations of irradiance variability.
- Tolerance to low sampling frequencies: since the methodology is not

Appendix A. Tables of results

Consideration for interpreting the table of results: The first column contains the relevant information about the benchmarking denoted by (see Tables A.1–A.9):

- n: the number of sensor per side in gridded sensor network or equivalent amount in non-gridded configuration
- L: the side length of the monitored area
- T_s : Sampling period.
- D: Intersensor distance in gridded sensor network configuration. This parameter does not apply for non-gridded setup.
- a.p.u: Area per unit. Indicates the surface covered for each sensor. In gridded configuration, this parameter is a constant, in non-gridded sensor network is the mean area covered for one sensor.

The number of successfull calculations of CMV from each set of 100 tests is indicated in parenthesis close to the method name (LCP, MCP, MAE).

Speed errors for sampling periods of 1 s.

Speed errors considering a $V_{max} = 30$ m/s.

Gridded vs. non-gridded.

based in accurate determination of lags, high sampling frequencies are not critical to obtain accurate estimations. Indeed, it has been observed how long sampling periods benefit the performance of the method with networks covering large areas. This has positive effects in real applications since low data rates benefit computational and communication aspects in monitoring and energy management systems.

- No special settings: the method can be directly implemented over an irradiance monitoring network without any additional device or specification. Thus, the sensor network become able to provide irradiance field and cloud motion estimations, which are the two main elements for very-short-term forecasting in PV systems.
- Versatility: The method is adaptable to any network layout. This is a valuable characteristic, as in most real-world cases, sensors are irregularly distributed due to area constraints and presence of obstacles.

Once the CMAE method has proved its validity in the synthetic framework, it would be necessary a validation in real-life conditions in order to detect possible problems derived from real instrumentation and communication systems that cannot be observed in the present study. It seems also relevant a study focused on kriging models for a better adaptation to non-gridded networks. Finally, the application of this method in larger networks should be tested, since no limitation regarding the size of monitoring area has been observed at the tested scales.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgement

This work was supported by the Spanish Ministry of Economy, Industry and Competitiveness Grant No. TEC2016-77632-C3-3-R. The authors would like to thank the Andalusian Government for funding the Research Unit PAIDI-TIC-168.

Table A.1

Errors n = 3 Ts = 1 s.

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 3 L = 10 m Ts = 1.0 s D = 5.0 m a.p.u = 11.1 m ²	ME [m/s]	LCE(71)	3.297	1.675	-1.691	-6.498	-12.790	-16.540	-6.179
		MCP(86)	0.214	-1.027	-3.088	-8.123	-14.734	-18.236	-7.805
		CMAE(100)	0.432	-0.082	-2.733	-5.925	-12.202	-16.165	-5.833
	RMSE [m/s]	LCE(71)	3.904	2.583	3.315	6.755	12.964	16.641	9.510
		MCP(86)	1.250	2.083	4.066	8.561	15.164	18.676	10.717
		CMAE(100)	0.726	0.479	3.814	6.124	12.283	16.235	8.541
	MAPE [%]	LCE(71)	79.054	27.312	20.140	37.833	54.568	59.521	40.611
		MCP(86)	20.393	21.194	26.115	47.055	62.988	65.297	41.408
		CMAE(100)	28.533	6.046	20.305	34.019	52.263	57.952	32.189
n = 3 L = 30 m Ts = 1.0 s D = 15.0 m a.p.u = 100.0 m ²	ME [m/s]	LCE(79)	5.778	4.328	2.296	3.328	0.194	-4.281	1.612
		MCP(91)	1.214	1.489	-0.811	-4.688	-4.115	-6.984	-2.428
		CMAE(100)	0.836	0.158	0.010	0.177	0.417	0.805	0.394
	RMSE [m/s]	LCE(79)	6.787	6.275	4.660	5.905	6.800	7.027	6.268
		MCP(91)	2.449	2.785	3.156	6.602	5.914	10.082	5.770
		CMAE(100)	1.407	1.000	1.179	1.940	1.214	1.502	1.384
	MAPE [%]	LCE(79)	194.288	63.068	30.564	27.345	23.672	21.104	45.053
		MCP(91)	40.700	22.306	18.508	30.437	22.055	29.312	25.702
		CMAE(100)	39.190	10.027	8.059	9.629	4.412	4.774	13.076
n = 3 L = 50 m Ts = 1.0 s D = 25.0 m a.p.u = 277.8 m ²	ME [m/s]	LCE(81)	3.726	2.288	-0.453	-3.285	-5.699	-6.111	-1.993
		MCP(95)	4.911	3.569	1.726	-0.480	-1.470	-1.407	0.961
		CMAE(100)	1.379	1.781	0.937	-0.217	0.037	-0.727	0.482
	RMSE [m/s]	LCE(81)	7.401	4.209	7.283	6.615	9.070	9.471	7.639
		MCP(95)	6.952	6.104	2.984	3.384	4.891	6.112	5.106
		CMAE(100)	3.470	3.370	2.115	2.378	1.623	2.546	2.654
	MAPE [%]	LCE(81)	169.458	43.533	36.014	29.743	30.084	29.064	49.987
		MCP(95)	135.460	64.885	17.927	15.900	18.955	16.924	40.230
		CMAE(100)	121.991	43.163	16.031	10.711	6.202	7.345	35.361
n = 3 L = 100 m Ts = 1.0 s D = 50.0 m a.p.u = 1111.1 m ²	ME [m/s]	LCE(37)	3.782	-0.038	-0.884	-5.659	-3.191	-12.785	-4.403
		MCP(93)	13.690	3.946	7.404	4.527	2.463	2.551	5.075
		CMAE(100)	1.173	4.785	3.271	3.235	1.188	-1.036	2.341
	RMSE [m/s]	LCE(37)	4.802	5.931	2.628	8.484	7.262	15.686	9.174
		MCP(93)	15.076	6.161	11.575	7.261	5.365	4.583	8.405
		CMAE(100)	4.203	8.114	7.626	4.591	3.976	2.383	5.683
	MAPE [%]	LCE(37)	137.609	74.366	16.892	45.683	26.151	46.304	45.605
		MCP(93)	428.633	53.043	61.432	26.575	14.108	12.401	72.440
		CMAE(100)	132.261	82.725	49.639	20.658	12.998	6.122	52.144

Table A.2

Errors n = 4 Ts = 1 s.

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 4 L = 10 m Ts = 1.0 s D = 3.3 m a.p.u = 6.3 m ²	ME [m/s]	LCE(79)	2.710	0.592	-2.350	-6.388	-11.256	-16.078	-6.556
		MCP(89)	-0.559	-2.204	-5.843	-9.167	-14.522	-20.091	-9.265
		CMAE(100)	0.190	-0.039	-2.389	-6.512	-11.012	-15.752	-5.871
	RMSE [m/s]	LCE(79)	3.665	2.196	3.354	6.745	11.382	16.181	9.388
		MCP(89)	1.268	2.750	6.308	9.874	14.823	20.402	11.851
		CMAE(100)	0.257	0.395	2.936	6.615	11.105	15.824	8.437
	MAPE [%]	LCE(79)	63.904	25.120	21.561	36.198	49.911	59.356	40.635
		MCP(89)	27.950	29.946	45.734	52.099	64.711	74.013	50.538
		CMAE(100)	7.693	4.238	18.229	37.075	48.815	57.996	28.893
n = 4 L = 30 m Ts = 1.0 s D = 10.0 m a.p.u = 56.3 m ²	ME [m/s]	LCE(84)	7.736	4.201	4.068	0.707	-3.485	-1.499	1.112
		MCP(93)	0.593	0.313	-2.984	-2.486	-5.145	-10.030	-3.373
		CMAE(100)	0.467	0.130	0.063	-0.266	0.059	-0.181	0.053
	RMSE [m/s]	LCE(84)	8.174	7.005	7.570	3.616	7.123	7.116	6.815
		MCP(93)	1.950	1.670	4.005	5.113	6.937	11.969	6.178
		CMAE(100)	1.078	0.626	1.023	0.732	1.128	0.927	0.944
	MAPE [%]	LCE(84)	376.079	61.807	50.161	16.956	23.356	19.019	58.975
		MCP(93)	39.205	18.178	25.743	20.919	22.931	37.590	25.470
		CMAE(100)	48.761	7.551	7.469	3.582	3.813	2.928	11.707

(continued on next page)

Table A.2 (continued)

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 4 L = 50 m T_s = 1.0 s D = 16.6 m a.p.u = 156.3 m ²	ME [m/s]	LCE(87)	7.898	2.282	1.785	-3.260	-8.093	-4.909	-0.874
		MCP(94)	3.088	1.482	-1.561	-3.634	-4.480	-8.744	-2.495
		CMAE(100)	1.257	1.066	0.368	-0.478	-0.084	-1.317	0.168
	RMSE [m/s]	LCE(87)	11.796	4.450	6.702	6.624	10.974	8.816	8.601
		MCP(94)	5.697	3.393	3.264	5.505	7.172	11.002	6.391
		CMAE(100)	2.277	1.544	1.355	1.627	2.353	3.463	2.164
	MAPE [%]	LCE(87)	370.725	43.599	41.117	27.599	37.409	29.192	86.177
		MCP(94)	95.533	37.231	20.009	26.242	21.356	32.175	35.364
		CMAE(100)	75.706	15.770	8.491	7.570	6.609	8.783	21.123
n = 4 L = 100 m T_s = 1.0 s D = 33.3 m a.p.u = 625.0 m ²	ME [m/s]	LCE(30)	12.776	-0.197	-3.070	4.168	-5.321	-1.958	3.301
		MCP(96)	5.043	5.518	-0.840	0.269	1.525	-6.245	0.673
		CMAE(100)	1.698	2.440	3.731	0.952	0.120	-0.279	1.453
	RMSE [m/s]	LCE(30)	14.487	3.654	3.519	7.807	8.283	6.241	9.308
		MCP(96)	6.890	9.306	2.621	3.219	4.690	8.465	6.419
		CMAE(100)	3.609	4.192	7.919	3.895	4.622	3.287	4.866
	MAPE [%]	LCE(30)	711.579	46.233	28.894	38.494	32.768	22.553	239.357
		MCP(96)	202.265	75.079	14.369	13.127	14.442	26.226	49.188
		CMAE(100)	107.969	48.579	34.868	19.624	16.810	10.377	38.629

Table A.3Errors n = 6 T_s = 1 s.

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 6 L = 10 m T_s = 1.0 s D = 2.0 m a.p.u = 2.8 m ²	ME [m/s]	LCE(66)	5.669	-0.000	-1.989	-6.185	-12.635	-16.249	-5.933
		MCP(90)	-0.723	-1.273	-4.649	-9.308	-13.353	-19.784	-8.352
		CMAE(100)	-0.252	-1.854	-2.157	-6.409	-10.811	-14.518	-5.769
	RMSE [m/s]	LCE(66)	5.799	1.884	2.769	6.587	12.817	16.306	8.931
		MCP(90)	1.190	2.198	5.506	9.596	13.781	20.102	11.046
		CMAE(100)	0.846	2.666	2.655	6.638	10.900	14.602	7.888
	MAPE [%]	LCE(66)	153.114	23.565	16.687	34.448	54.357	59.138	42.611
		MCP(90)	18.941	16.351	35.911	52.941	57.638	72.496	43.192
		CMAE(100)	18.034	24.599	17.042	36.045	46.855	53.230	31.896
n = 6 L = 30 m T_s = 1.0 s D = 6.0 m a.p.u = 25.0 m ²	ME [m/s]	LCE(79)	3.756	4.746	1.433	3.538	-1.844	-0.616	1.560
		MCP(95)	0.838	-1.689	-3.959	-2.761	-4.789	-2.776	-2.735
		CMAE(100)	0.635	-0.469	-0.785	0.061	-4.473	-3.281	-1.378
	RMSE [m/s]	LCE(79)	3.756	7.279	5.530	6.475	6.797	7.300	6.709
		MCP(95)	1.479	2.342	4.712	4.793	6.962	4.645	4.633
		CMAE(100)	0.972	1.559	2.703	0.469	9.212	8.986	5.321
	MAPE [%]	LCE(79)	104.170	64.083	24.926	29.688	22.545	21.604	34.279
		MCP(95)	45.764	23.747	31.980	18.060	22.270	11.660	23.908
		CMAE(100)	44.796	11.972	8.430	2.342	19.807	13.516	15.965
n = 6 L = 50 m T_s = 1.0 s D = 10.0 m a.p.u = 69.4 m ²	ME [m/s]	LCE(83)	7.235	1.286	-2.299	-1.900	-6.229	-7.472	-1.988
		MCP(99)	3.820	-0.542	-2.412	-5.722	-4.179	-4.708	-2.238
		CMAE(100)	1.096	-0.003	-0.021	0.224	0.021	-0.245	0.171
	RMSE [m/s]	LCE(83)	8.828	2.983	4.958	5.561	10.591	11.784	8.292
		MCP(99)	8.812	1.482	3.809	7.448	6.367	6.928	6.219
		CMAE(100)	2.178	0.629	0.885	0.567	0.933	0.858	1.155
	MAPE [%]	LCE(83)	216.648	26.316	30.047	25.114	42.024	32.889	58.819
		MCP(99)	173.334	12.315	21.591	35.991	18.716	17.510	45.055
		CMAE(100)	58.063	7.253	5.843	2.944	3.458	2.750	13.611
n = 6 L = 100 m T_s = 1.0 s D = 20.0 m a.p.u = 277.8 m ²	ME [m/s]	LCE(26)	8.261	6.267	-6.269	-4.434	NaN	-4.784	0.248
		MCP(100)	6.704	2.166	-0.071	-1.953	-3.358	-8.557	-0.858
		CMAE(100)	3.936	1.831	0.726	-0.146	0.003	0.621	1.142
	RMSE [m/s]	LCE(26)	9.336	10.798	6.345	7.047	NaN	8.188	8.648
		MCP(100)	8.920	3.604	2.821	3.296	5.910	10.695	6.485
		CMAE(100)	5.114	3.042	1.937	1.297	2.233	1.486	2.803
	MAPE [%]	LCE(26)	330.492	121.264	50.178	31.947	NaN	20.713	117.097
		MCP(100)	381.536	33.625	13.771	14.054	17.349	32.499	76.592
		CMAE(100)	209.549	29.884	14.277	5.924	8.688	4.235	42.740

Table A.4

Errors n = 10 Ts = 1 s.

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 10 L = 10 m Ts = 1.0 s D = 1.1 m a.p.u = 1.0 m ²	ME[m/s]	LCE(78)	-0.573	0.581	-1.706	-5.874	-12.150	-17.844	-6.697
		MCP(92)	-0.461	-1.933	-4.483	-9.903	-16.098	-21.983	-9.619
		CMAE(100)	0.438	1.001	-1.164	-5.826	-10.754	-15.043	-4.999
	RMSE [m/s]	LCE(78)	0.573	2.044	2.932	6.286	12.273	18.053	9.600
		MCP(92)	0.851	2.982	5.033	10.318	16.355	22.255	12.436
		CMAE(100)	1.108	1.225	1.860	6.075	10.836	15.152	7.805
	MAPE [%]	LCE(78)	11.452	23.466	18.800	33.298	53.137	63.854	36.917
		MCP(92)	23.436	29.218	34.929	56.123	69.879	78.768	50.469
		CMAE(100)	32.703	15.002	9.944	33.010	46.693	53.864	31.285
n = 10 L = 30 m Ts = 1.0 s D = 3.3 m a.p.u = 9.0 m ²	ME [m/s]	LCE(86)	7.046	2.845	1.366	0.683	-1.108	-0.775	1.234
		MCP(95)	-0.703	-1.139	-3.559	-4.471	-5.196	-9.650	-4.265
		CMAE(100)	0.683	0.088	-0.106	-0.044	-0.851	-0.902	-0.176
	RMSE [m/s]	LCE(86)	9.980	4.360	4.136	5.436	6.254	4.433	5.626
		MCP(95)	1.325	2.114	4.784	6.399	7.034	11.074	6.467
		CMAE(100)	2.031	0.781	0.939	0.977	1.482	1.702	1.391
	MAPE [%]	LCE(86)	412.798	40.514	28.090	27.384	22.916	13.214	62.439
		MCP(95)	24.858	19.734	28.059	25.362	24.209	35.049	26.270
		CMAE(100)	57.346	6.353	4.278	3.109	4.520	4.372	13.475
n = 10 L = 50 m Ts = 1.0 s D = 5.5 m a.p.u = 25.0 m ²	ME [m/s]	LCE(86)	7.069	1.786	-3.531	-2.130	-7.020	-9.346	-2.485
		MCP(97)	0.813	-2.268	-3.190	-3.759	-4.623	-8.391	-3.586
		CMAE(100)	0.275	0.002	0.325	-0.035	-2.669	-0.034	-0.284
	RMSE [m/s]	LCE(86)	7.644	3.892	4.781	7.117	8.620	11.281	7.506
		MCP(97)	2.898	2.979	4.511	5.395	7.941	10.589	6.286
		CMAE(100)	0.677	0.428	0.505	0.378	7.220	0.439	2.741
	MAPE [%]	LCE(86)	323.267	34.565	29.789	32.312	33.105	35.356	66.803
		MCP(97)	82.705	30.870	25.691	22.150	20.695	31.254	34.918
		CMAE(100)	28.517	5.050	3.466	1.542	12.528	1.168	8.780
n = 10 L = 100 m Ts = 1.0 s D = 11.1 m a.p.u = 100.0 m ²	ME [m/s]	LCE(32)	3.745	3.330	1.755	11.062	-7.120	-3.487	-0.093
		MCP(98)	1.511	-0.348	-3.209	-6.643	-5.054	-11.438	-4.247
		CMAE(100)	3.251	1.603	1.006	0.013	-0.159	-1.016	0.817
	RMSE [m/s]	LCE(32)	3.924	5.937	7.420	11.803	11.603	8.053	8.457
		MCP(98)	2.771	1.633	4.715	8.292	6.452	12.610	7.121
		CMAE(100)	5.592	3.058	2.284	1.779	1.457	1.982	3.082
	MAPE [%]	LCE(32)	93.111	77.510	48.569	59.425	40.484	16.371	51.531
		MCP(98)	52.720	16.304	26.814	37.293	22.284	41.004	32.829
		CMAE(100)	122.783	25.267	13.753	6.982	5.573	5.518	31.375

Table A.5Errors n = 3 V_{max} = 30 m/s

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 3 L = 10 m Ts = 0.3 s D = 5.0 m a.p.u = 11.1 m ²	ME [m/s]	LCE(85)	8.967	2.963	2.076	1.240	-1.029	-5.561	0.205
		MCP(88)	1.914	2.723	1.085	-0.161	-5.415	-5.335	-1.337
		CMAE(100)	0.365	0.362	0.287	-0.362	-0.143	0.493	0.165
	RMSE [m/s]	LCE(85)	9.163	3.708	4.785	3.521	4.090	7.479	5.145
		MCP(88)	3.764	5.005	2.381	2.322	7.529	6.365	5.316
		CMAE(100)	0.697	1.121	1.360	1.688	0.796	1.434	1.222
	MAPE [%]	LCE(85)	240.799	46.843	28.889	15.006	13.818	22.104	33.758
		MCP(88)	50.882	51.976	13.902	10.286	27.775	19.241	28.108
		CMAE(100)	27.992	12.907	8.983	8.316	3.078	4.587	10.127
n = 3 L = 30 m Ts = 1.0 s D = 15.0 m a.p.u = 100.0 m ²	ME [m/s]	LCE(79)	5.778	4.328	2.296	3.328	0.194	-4.281	1.612
		MCP(91)	1.214	1.489	-0.811	-4.688	-4.115	-6.984	-2.428
		CMAE(100)	0.836	0.158	0.010	0.177	0.417	0.805	0.394
	RMSE [m/s]	LCE(79)	6.787	6.275	4.660	5.905	6.800	7.027	6.268
		MCP(91)	2.449	2.785	3.156	6.602	5.914	10.082	5.770
		CMAE(100)	1.407	1.000	1.179	1.940	1.214	1.502	1.384
	MAPE [%]	LCE(79)	194.288	63.068	30.564	27.345	23.672	21.104	45.053
		MCP(91)	40.700	22.306	18.508	30.437	22.055	29.312	25.702
		CMAE(100)	39.190	10.027	8.059	9.629	4.412	4.774	13.076

(continued on next page)

Table A.5 (continued)

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 3 L = 50 m Ts = 1.6 s D = 25.0 m a.p.u = 277.8 m ²	ME [m/s]	LCE(44)	5.723	−0.725	4.469	−2.151	−5.967	−5.213	−1.625
		MCP(91)	2.240	−0.344	−3.257	−3.664	−7.589	−8.951	−3.997
		CMAE(100)	1.133	0.758	0.294	1.061	0.655	0.590	0.752
	RMSE [m/s]	LCE(44)	7.217	2.477	9.478	5.564	9.141	9.166	7.794
		MCP(91)	3.392	3.564	4.894	6.001	10.178	11.687	7.513
		CMAE(100)	2.118	1.799	1.105	1.835	1.501	1.718	1.705
	MAPE [%]	LCE(44)	159.791	27.010	54.201	22.284	31.083	28.531	41.408
		MCP(91)	66.973	33.745	28.494	25.701	35.254	32.796	34.700
		CMAE(100)	84.786	18.783	6.948	8.587	4.796	5.562	20.631
n = 3 L = 100 m Ts = 3.3 s D = 50.0 m a.p.u = 1111.1 m ²	ME [m/s]	LCE(18)	25.303	NaN	−0.495	3.209	−0.745	−9.627	0.883
		MCP(96)	6.803	1.169	−1.282	−5.405	−7.860	−10.218	−3.029
		CMAE(100)	2.451	1.900	0.968	−0.237	−0.967	0.174	0.638
	RMSE [m/s]	LCE(18)	25.303	NaN	4.196	6.019	9.742	9.844	9.362
		MCP(96)	9.796	3.012	2.542	6.508	9.736	12.287	8.127
		CMAE(100)	3.847	3.205	2.707	2.243	4.451	1.888	3.236
	MAPE [%]	LCE(18)	506.061	NaN	27.979	26.311	31.205	34.823	55.732
		MCP(96)	332.885	30.440	16.431	32.442	34.702	37.108	74.723
		CMAE(100)	110.546	31.959	15.151	8.516	10.613	5.541	28.675

Table A.6Errors n = 4 V_{max} = 30 m/s

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 4 L = 10 m Ts = 0.3 s D = 3.3 m a.p.u = 6.3 m ²	ME [m/s]	LCE(84)	4.860	1.503	2.589	0.100	−2.319	−4.637	−0.238
		MCP(85)	1.482	1.344	−1.028	−1.364	−1.416	−4.468	−1.166
		CMAE(100)	3.226	2.774	0.696	−0.442	−1.436	−0.729	0.618
	RMSE [m/s]	LCE(84)	5.384	3.048	6.220	4.428	4.828	5.738	5.088
		MCP(85)	1.999	2.524	2.234	2.431	4.185	7.867	4.127
		CMAE(100)	6.770	4.429	2.960	2.807	2.803	2.151	3.945
	MAPE [%]	LCE(84)	156.446	34.991	30.151	20.444	17.402	17.264	31.272
		MCP(85)	43.414	21.428	13.775	10.084	13.804	23.395	18.382
		CMAE(100)	154.222	45.811	12.190	11.837	9.852	5.952	38.936
n = 4 L = 30 m Ts = 1.0 s D = 10.0 m a.p.u = 56.3 m ²	ME [m/s]	LCE(84)	7.736	4.201	4.068	0.707	−3.485	−1.499	1.112
		MCP(93)	0.593	0.313	−2.984	−2.486	−5.145	−10.030	−3.373
		CMAE(100)	0.467	0.130	0.063	−0.266	0.059	−0.181	0.053
	RMSE [m/s]	LCE(84)	8.174	7.005	7.570	3.616	7.123	7.116	6.815
		MCP(93)	1.950	1.670	4.005	5.113	6.937	11.969	6.178
		CMAE(100)	1.078	0.626	1.023	0.732	1.128	0.927	0.944
	MAPE [%]	LCE(84)	376.079	61.807	50.161	16.956	23.356	19.019	58.975
		MCP(93)	39.205	18.178	25.743	20.919	22.931	37.590	25.470
		CMAE(100)	48.761	7.551	7.469	3.582	3.813	2.928	11.707
n = 4 L = 50 m Ts = 1.6 s D = 16.6 m a.p.u = 156.3 m ²	ME [m/s]	LCE(47)	2.835	3.872	1.897	−0.989	−2.210	−8.666	0.549
		MCP(94)	4.631	0.452	−3.569	−6.045	−7.983	−8.761	−4.167
		CMAE(100)	3.057	0.675	0.389	−1.434	−1.612	−3.116	−0.346
	RMSE [m/s]	LCE(47)	3.160	5.828	5.300	4.721	8.111	13.202	6.697
		MCP(94)	6.392	1.536	4.463	7.316	9.232	10.665	7.286
		CMAE(100)	4.923	1.629	1.700	2.725	2.491	4.749	3.191
	MAPE [%]	LCE(47)	84.897	55.925	31.297	20.237	30.282	34.278	38.535
		MCP(94)	197.557	16.127	30.021	36.883	35.350	32.181	48.086
		CMAE(100)	143.058	18.248	10.175	10.616	8.015	12.980	31.485
n = 4 L = 100 m Ts = 3.3 s D = 33.3 m a.p.u = 625.0 m ²	ME [m/s]	LCE(19)	7.736	1.764	1.060	−12.789	1.073	−3.184	−0.922
		MCP(100)	3.833	0.274	−4.701	−5.862	−8.324	−13.311	−4.801
		CMAE(100)	2.762	3.897	2.061	−0.629	−0.621	−1.668	0.998
	RMSE [m/s]	LCE(19)	10.222	2.950	1.588	12.909	8.202	8.173	7.876
		MCP(100)	4.828	1.906	5.507	7.028	9.567	13.776	8.017
		CMAE(100)	3.780	5.223	3.322	3.085	2.935	3.400	3.738
	MAPE [%]	LCE(19)	154.721	45.694	10.365	70.312	33.300	21.471	44.577
		MCP(100)	198.021	22.929	37.555	36.087	37.609	49.155	58.887
		CMAE(100)	115.551	59.548	20.874	12.849	10.664	10.308	36.643

Table A.7Errors n = 6 V_{max} = 30 m/s

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 6 L = 10 m Ts = 0.3 s D = 2.0 m a.p.u = 2.8 m ²	ME [m/s]	LCE(85)	5.709	3.436	1.656	0.758	-1.987	-3.906	0.412
		MCP(89)	1.255	-1.661	-1.282	-1.538	-2.718	-4.199	-1.979
		CMAE(100)	-0.068	0.071	-0.027	0.039	0.080	-0.081	0.004
	RMSE [m/s]	LCE(85)	9.303	5.530	4.027	2.675	5.212	5.840	5.327
		MCP(89)	2.794	2.651	2.543	3.653	5.352	6.244	4.256
		CMAE(100)	0.458	0.483	0.449	0.588	0.464	0.693	0.535
	MAPE [%]	LCE(85)	183.391	50.948	23.115	11.262	18.172	18.783	37.388
		MCP(89)	56.482	26.237	12.566	14.029	16.513	17.784	20.787
		CMAE(100)	10.609	4.983	3.201	2.813	1.714	1.897	3.810
n = 6 L = 30 m Ts = 1.0 s D = 6.0 m a.p.u = 25.0 m ²	ME [m/s]	LCE(79)	3.756	4.746	1.433	3.538	-1.844	-0.616	1.560
		MCP(95)	0.838	-1.689	-3.959	-2.761	-4.789	-2.776	-2.735
		CMAE(100)	0.635	-0.469	-0.785	0.061	-4.473	-3.281	-1.378
	RMSE [m/s]	LCE(79)	3.756	7.279	5.530	6.475	6.797	7.300	6.709
		MCP(95)	1.479	2.342	4.712	4.793	6.962	4.645	4.633
		CMAE(100)	0.972	1.559	2.703	0.469	9.212	8.986	5.321
	MAPE [%]	LCE(79)	104.170	64.083	24.926	29.688	22.545	21.604	34.279
		MCP(95)	45.764	23.747	31.980	18.060	22.270	11.660	23.908
		CMAE(100)	44.796	11.972	8.430	2.342	19.807	13.516	15.965
n = 6 L = 50 m Ts = 1.6 s D = 10.0 m a.p.u = 69.4 m ²	ME [m/s]	LCE(47)	6.305	2.411	3.166	-2.027	1.286	-1.316	1.482
		MCP(92)	-0.471	-2.866	-4.169	-3.272	-7.412	-8.085	-4.672
		CMAE(100)	0.631	0.073	-0.287	0.122	-0.069	-0.015	0.064
	RMSE [m/s]	LCE(47)	8.032	6.973	9.387	9.150	6.141	4.687	7.408
		MCP(92)	1.316	3.910	6.297	5.356	9.130	10.728	7.126
		CMAE(100)	1.260	0.334	0.667	0.548	0.558	0.583	0.699
	MAPE [%]	LCE(47)	135.909	49.500	55.286	43.286	23.074	15.029	44.622
		MCP(92)	28.221	34.365	34.708	21.863	33.104	30.517	30.867
		CMAE(100)	51.318	3.592	4.506	2.637	2.094	1.691	10.066
n = 6 L = 100 m Ts = 3.3 s D = 20.0 m a.p.u = 277.8 m ²	ME [m/s]	LCE(19)	8.740	-2.815	5.817	-0.639	-3.852	-6.580	-1.091
		MCP(97)	1.776	-2.094	-5.660	-4.933	-10.126	-9.823	-5.221
		CMAE(100)	1.988	0.444	-0.354	0.115	0.038	0.074	0.378
	RMSE [m/s]	LCE(19)	10.533	3.447	6.443	1.906	16.110	7.017	8.958
		MCP(97)	2.623	2.618	6.430	6.000	11.188	10.578	7.455
		CMAE(100)	2.702	1.537	1.300	0.523	0.714	0.494	1.424
	MAPE [%]	LCE(19)	235.549	29.852	41.634	9.287	73.628	24.139	65.431
		MCP(97)	124.422	27.695	45.491	29.037	44.988	35.622	51.062
		CMAE(100)	114.268	12.019	5.571	2.501	2.795	1.592	22.694

Table A.8Errors n = 10 V_{max} = 30 m/s

Test	Error	Method	Speed bins [m/s]						Total
			0–5	5–10	10–15	15–20	20–25	25–30	
n = 10 L = 10 m Ts = 0.3 s D = 1.1 m a.p.u = 1.0 m ²	ME [m/s]	LCE(82)	6.984	2.033	1.640	1.139	-0.259	-5.238	0.051
		MCP(88)	0.028	-1.799	-0.900	-1.473	-2.081	-2.140	-1.575
		CMAE(100)	4.007	0.867	0.317	-1.167	-1.246	-2.777	0.038
	RMSE [m/s]	LCE(82)	7.807	3.288	3.063	3.624	3.601	6.919	4.526
		MCP(88)	0.543	2.534	2.024	2.983	4.395	5.390	3.618
		CMAE(100)	6.150	3.163	2.615	3.185	2.808	3.958	3.884
	MAPE [%]	LCE(82)	193.982	29.003	18.935	16.184	13.396	19.287	25.653
		MCP(88)	14.770	22.376	11.140	10.406	13.120	11.610	13.873
		CMAE(100)	175.302	16.625	12.608	12.926	8.265	10.647	41.422
n = 10 L = 30 m Ts = 1.0 s D = 3.3 m a.p.u = 9.0 m ²	ME [m/s]	LCE(86)	7.046	2.845	1.366	0.683	-1.108	-0.775	1.234
		MCP(95)	-0.703	-1.139	-3.559	-4.471	-5.196	-9.650	-4.265
		CMAE(100)	0.683	0.088	-0.106	-0.044	-0.851	-0.902	-0.176
	RMSE [m/s]	LCE(86)	9.980	4.360	4.136	5.436	6.254	4.433	5.626
		MCP(95)	1.325	2.114	4.784	6.399	7.034	11.074	6.467
		CMAE(100)	2.031	0.781	0.939	0.977	1.482	1.702	1.391
	MAPE [%]	LCE(86)	412.798	40.514	28.090	27.384	22.916	13.214	62.439
		MCP(95)	24.858	19.734	28.059	25.362	24.209	35.049	26.270
		CMAE(100)	57.346	6.353	4.278	3.109	4.520	4.372	13.475

(continued on next page)

Table A.8 (continued)

Test	Error	Method	Speed bins [m/s]							Total
			0–5	5–10	10–15	15–20	20–25	25–30		
n = 10 L = 50 m Ts = 1.6 s D = 5.5 m a.p.u = 25.0 m ²	ME [m/s]	LCE(49)	4.079	0.633	1.982	1.132	-7.080	-5.419	-0.804	
		MCP(96)	0.013	-1.316	-3.169	-6.437	-6.978	-9.924	-4.653	
		CMAE(100)	2.847	3.575	1.403	0.502	0.068	0.539	1.507	
	RMSE [m/s]	LCE(49)	5.379	2.492	6.544	7.048	10.001	7.542	7.003	
		MCP(96)	0.789	2.443	4.416	8.009	10.159	12.596	7.699	
		CMAE(100)	8.336	8.215	5.889	2.614	1.007	1.115	5.535	
	MAPE [%]	LCE(49)	170.841	25.900	41.921	30.869	32.225	24.383	48.515	
		MCP(96)	17.681	19.215	26.995	37.920	30.598	36.252	28.068	
		CMAE(100)	177.958	47.135	12.670	7.033	2.469	2.552	42.614	
n = 10 L = 100 m Ts = 3.3 s D = 11.1 m a.p.u = 100.0 m ²	ME [m/s]	LCE(23)	-0.675	1.594	2.114	-0.024	-11.926	-1.557	-0.151	
		MCP(100)	0.127	-2.275	-4.442	-8.316	-13.695	-17.099	-7.449	
		CMAE(100)	4.156	0.895	0.407	-0.575	-1.216	-2.127	0.334	
	RMSE [m/s]	LCE(23)	0.675	3.128	3.278	4.065	11.967	1.557	4.796	
		MCP(100)	1.663	2.938	5.459	9.492	14.256	17.794	10.197	
		CMAE(100)	7.354	2.692	1.764	1.106	2.424	3.319	3.764	
	MAPE [%]	LCE(23)	13.506	28.639	23.908	18.455	54.720	5.398	24.699	
		MCP(100)	71.148	29.680	35.551	47.270	59.724	61.068	51.222	
		CMAE(100)	226.691	19.753	7.352	4.460	7.267	10.080	48.539	

Table A.9Errors n = 6 V_{max} = 30 m/s

Test	Error	Method	Speed bins [m/s]							Total
			0–5	5–10	10–15	15–20	20–25	25–30		
n = 6 L = 10 m Ts = 0.3 s D = 2.0 m a.p.u = 2.8 m ²	ME [m/s]	G-CMAE(92)	-0.068	0.071	-0.027	0.039	0.080	-0.081	0.004	
		NG-CMAE(100)	0.323	0.884	1.643	1.684	2.269	4.603	1.798	
		G-CMAE(92)	0.458	0.483	0.449	0.588	0.464	0.693	0.535	
	RMSE [m/s]	NG-CMAE(100)	0.512	1.082	1.872	1.909	2.665	5.490	2.565	
		G-CMAE(92)	10.609	4.983	3.201	2.813	1.714	1.897	3.810	
		NG-CMAE(100)	17.899	11.839	12.657	9.752	9.908	16.649	12.833	
	ME [m/s]	G-CMAE(100)	0.635	-0.469	-0.785	0.061	-4.473	-3.281	-1.378	
		NG-CMAE(100)	0.538	1.024	1.392	1.816	2.547	3.428	1.782	
		G-CMAE(100)	0.972	1.559	2.703	0.469	9.212	8.986	5.321	
a.p.u = 25.0 m²	RMSE [m/s]	NG-CMAE(100)	0.811	1.222	1.650	2.038	2.893	3.790	2.298	
		G-CMAE(100)	44.796	11.972	8.430	2.342	19.807	13.516	15.965	
		NGCMAE(100)	25.709	13.384	11.255	10.370	11.370	12.377	14.256	
	ME [m/s]	G-CMAE(94)	0.631	0.073	-0.287	0.122	-0.069	-0.015	0.064	
		NG-CMAE(100)	1.124	0.942	1.321	2.828	3.099	5.662	2.430	
		G-CMAE(94)	1.260	0.334	0.667	0.548	0.558	0.583	0.699	
	MAPE [%]	NG-CMAE(100)	1.672	1.402	1.579	3.458	3.571	6.418	3.398	
		G-CMAE(94)	51.318	3.592	4.506	2.637	2.094	1.691	10.066	
		NG-CMAE(100)	49.535	16.409	10.563	16.031	13.831	20.723	21.329	
n = 6 L = 50 m Ts = 1.6 s D = 10.0 m a.p.u = 69.4 m ²	ME [m/s]	G-CMAE(94)	1.988	0.444	-0.354	0.115	0.038	0.074	0.378	
		NG-CMAE(100)	2.869	1.864	2.393	2.171	3.312	4.790	2.900	
		G-CMAE(94)	2.702	1.537	1.300	0.523	0.714	0.494	1.42	
	RMSE [m/s]	NG-CMAE(100)	3.908	2.305	3.176	2.427	4.021	5.135	3.643	
		G-CMAE(94)	114.268	12.019	5.571	2.501	2.795	1.592	22.694	
		NG-CMAE(100)	117.018	23.472	17.152	12.822	14.576	17.333	34.413	

References

- Agüera-Pérez, A., Palomares-Salas, J.C., de la Rosa, J.J.G., Florencias-Olivero, O., 2018. Weather forecasts for microgrid energy management: Review, discussion and recommendations. Appl. Energy 228, 265–278. <http://www.sciencedirect.com/science/article/pii/S0306261918309565>.
- Alonso-Montesinos, J., Battles, F.J., 2015. Solar radiation forecasting in the short- and medium-term under all sky conditions. Energy 83, 387–393. <https://doi.org/10.1016/j.energy.2015.02.036>.
- Anvari, M., Werther, B., Lohmann, G., Wächter, M., Peinke, J., Beck, H.-P., 2017. Suppressing power output fluctuations of photovoltaic power plants. Sol. Energy 157, 735–743. <http://www.sciencedirect.com/science/article/pii/S0038092X17307193>.
- Aryaputera, A.W., Yang, D., Zhao, L., Walsh, W.M., 2015. Very short-term irradiance forecasting at unobserved locations using spatio-temporal kriging. Sol. Energy 122, 1266–1278. <http://www.sciencedirect.com/science/article/pii/S0038092X15005745>.
- Bosch, J.L., Kleissl, J., 2013. Cloud motion vectors from a network of ground sensors in a solar power plant. Sol. Energy 95, 13–20. <https://doi.org/10.1016/j.solener.2013.05.027>.
- Bosch, J.L., Zheng, Y., Kleissl, J., 2013. Deriving cloud velocity from an array of solar radiation measurements. Sol. Energy 87 (1), 196–203.
- Dyreson, A.R., Morgan, E.R., Monger, S.H., Acker, T.L., 2014. Modeling solar irradiance smoothing for large pv power plants using a 45-sensor network and the wavelet variability model. Sol. Energy 110, 482–495. <http://www.sciencedirect.com/science/article/pii/S0038092X14004678>.

- e Silva, R.A., Brito, M.C., 2018. Impact of network layout and time resolution on spatio-temporal solar forecasting. *Sol. Energy* 163, 329–337. <http://www.sciencedirect.com/science/article/pii/S0038092X18301166>.
- Escrí, H., Batllés, F.J., Alonso, J., Baena, F.M., Bosch, J.L., Salbidegoitia, I.B., Burgaleta, J.I., 2013. Cloud detection, classification and motion estimation using geostationary satellite imagery for cloud cover forecast. *Energy* 55, 853–859. <https://doi.org/10.1016/j.energy.2013.01.054>.
- Espinosa-Gavira, M.J., Agüera-Pérez, A., de la Rosa, J.J.G., Palomares-Salas, J.C., Sierra-Fernández, J.M., 2018. An on-line low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV systems. *Sensors (Switzerland)* 18 (10), 1–12.
- Fung, V., Bosch, J.L., Roberts, S.W., Kleissl, J., 2014. Cloud shadow speed sensor. *Atmos. Meas. Tech.* 7 (6), 1693–1700. <https://www.atmos-meas-tech.net/7/1693/2014/>.
- IEA International Energy Agency, 2018. IEA PVPS Trends 2018 in Photovoltaic Application. Tech. rep., IEA International Energy Agency. www.iea-pvps.org.
- Jamaly, M., Kleissl, J., 2018. Robust cloud motion estimation by spatio-temporal correlation analysis of irradiance data. *Sol. Energy* 159 (February 2017), 306–317. <https://doi.org/10.1016/j.solener.2017.10.075>.
- Kuhn, P., Wirtz, M., Wilbert, S., Bosch, J., Wang, G., Ramirez, L., Heinemann, D., Pitz-Paal, R., Oct 2018. Field validation and benchmarking of a cloud shadow speed sensor. *Sol. Energy* 173, 229–245. <https://www.sciencedirect.com/science/article/pii/S0038092X18307175?via%3Dihub>.
- Lappalainen, K., Valkealahti, S., 2016. Analysis of shading periods caused by moving clouds. *Sol. Energy* 135, 188–196. <https://doi.org/10.1016/j.solener.2016.05.050>.
- Lappalainen, K., Valkealahti, S., Nov 2016. Apparent velocity of shadow edges caused by moving clouds. *Sol. Energy* 138, 47–52. <https://www.sciencedirect.com/science/article/pii/S0038092X16304030?via%3Dihub>.
- Lim, S., Apostolopoulos, J.G., Gamal, A.E., Aug 2005. Optical flow estimation using temporally oversampled video. *IEEE Trans. Image Process.* 14 (8), 1074–1087.
- Liu, C., Liu, H., Liu, Y., Li, T., Wang, T., 2019. Normalized cross correlation image stitching algorithm based on minimum spanning tree. *Optik* 179, 610–616. <http://www.sciencedirect.com/science/article/pii/S003040402618316978>.
- Lohmann, G.M., Hammer, A., Monahan, A.H., Schmidt, T., Heinemann, D., 2017. Simulating clear-sky index increment correlations under mixed sky conditions using a fractal cloud model. *Sol. Energy* 150, 255–264. <http://www.sciencedirect.com/science/article/pii/S0038092X17303419>.
- Lohmann, G.M., Monahan, A.H., Heinemann, D., 2016. Local short-term variability in solar irradiance. *Atmos. Chem. Phys.* 16 (10), 6365–6379. <https://www.atmos-chem-phys.net/16/6365/2016/>.
- Mazzola, S., Vergara, C., Astolfi, M., Li, V., Perez-Arriaga, I., Macchi, E., 2017. Assessing the value of forecast-based dispatch in the operation of off-grid rural microgrids. *Renewable Energy* 108, 116–125. <http://www.sciencedirect.com/science/article/pii/S096014811730126X>.
- Monger, S.H., Morgan, E.R., Dyreson, A.R., Acker, T.L., 2016. Applying the kriging method to predicting irradiance variability at a potential pv power plant. *Renewable Energy* 86, 602–610. <http://www.sciencedirect.com/science/article/pii/S0960148115302585>.
- Peng, Z., Yu, D., Huang, D., Heiser, J., Yoo, S., Kalb, P., 2015. 3D cloud detection and tracking system for solar forecast using multiple sky imagers. *Sol. Energy* 118, 496–519. <https://doi.org/10.1016/j.solener.2015.05.037>.
- Scolari, E., Sossan, F., Paolone, M., 2016. Irradiance prediction intervals for pv stochastic generation in microgrid applications. *Sol. Energy* 139, 116–129. <http://www.sciencedirect.com/science/article/pii/S0038092X16304364>.
- Smithpeter, I., 2018. A Low-Cost IoT Approach to Real-Time Cloud Motion Detection. In: SOLAR 2018–47th National Solar Conference of the American Solar Energy Society. United States, pp. 111–119.
- Torregrossa, D., Boudec, J.-Y.L., Paolone, M., 2016. Model-free computation of ultra-short-term prediction intervals of solar irradiance. *Sol. Energy* 124, 57–67. <http://www.sciencedirect.com/science/article/pii/S0038092X15006234>.
- Wang, F., Zhen, Z., Liu, C., Mi, Z., Hodge, B.M., Shafie-khah, M., Catalão, J.P., 2018. Image phase shift invariance based cloud motion displacement vector calculation method for ultra-short-term solar PV power forecasting. *Energy Convers. Manage.* 157 (September 2017), 123–135.
- Wang, G., Kurtz, B., Kleissl, J., 2016. Cloud base height from sky imager and cloud speed sensor. *Sol. Energy* 131, 208–221. <http://www.sciencedirect.com/science/article/pii/S0038092X16001237>.
- Yan, R., Saha, T.K., May 2012. Investigation of voltage stability for residential customers due to high photovoltaic penetrations. *IEEE Trans. Power Syst.* 27 (2), 651–662.
- Yang, D., 2017. On adding and removing sensors in a solar irradiance monitoring network for areal forecasting and pv system performance evaluation. *Sol. Energy* 155, 1417–1430. <http://www.sciencedirect.com/science/article/pii/S0038092X17306461>.
- Yang, D., Kleissl, J., Gueymard, C.A., Pedro, H.T.C., Coimbra, C.F.M., 2017. History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Sol. Energy* (November) 0–1. <https://doi.org/10.1016/j.solener.2017.11.023>.
- Zhou, K., Fu, C., Yang, S., 2016. Big data driven smart energy management: From big data to big insights. *Renew. Sustain. Energy Rev.* 56, 215–225. <http://www.sciencedirect.com/science/article/pii/S1364032115013179>.

Apéndice III

Article

Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

Manuel Jesús Espinosa-Gavira ^{*,†}, Agustín Agüera-Pérez [†], José María Sierra-Fernández , Juan José González de-la-Rosa , Jose Carlos Palomares-Salas  and Olivia Florencias-Oliveros 

Research Group PAIDI-TIC-168, Computational Instrumentation and Industrial Electronics (ICEI), University of Cadiz, ETSI of Algeciras, Av. Ramon Puyol S/N, Algeciras, 11202 Cadiz, Spain; agustin.aguera@uca.es (A.A.-P.); josemaria.sierra@uca.es (J.M.S.-F.); juanjose.delarosa@uca.es (J.J.G.d.-l.-R.); josecarlos.palomares@uca.es (J.C.P.-S.); olivia.florencias@uca.es (O.F.-O.)

* Correspondence: manuel.espinosa@uca.es

† These authors contributed equally to this work.

Abstract: Cloud-induced photovoltaic variability can affect grid stability and power quality, especially in electricity systems with high penetration levels. The availability of irradiance field forecasts in the scale of seconds and meters is fundamental for an adequate control of photovoltaic systems in order to minimize their impact on distribution networks. Irradiance sensor networks have proved to be efficient tools for supporting these forecasts, but the costs of monitoring systems with the required specifications are economically justified only for large plants and research purposes. This study deals with the design and test of a wireless irradiance sensor network as an adaptable operational solution for photovoltaic systems capable of meeting the measurement specifications necessary for capturing the clouds passage. The network was based on WiFi, comprised 16 pyranometers, and proved to be stable at sampling periods up to 25 ms, providing detailed spatial representations of the irradiance field and its evolution. As a result, the developed network was capable of achieving comparable specifications to research wired irradiance monitoring network with the advantages in costs and flexibility of the wireless technology, thus constituting a valuable tool for supporting nowcasting systems for photovoltaic management and control.

Keywords: irradiance WSN; high-performance WSN; solar irradiance; low-cost WSN; online wireless sensor network; irradiance network; nowcasting



Citation: Espinosa-Gavira, M.J.; Agüera-Pérez, A.; Sierra-Fernández, J.M.; González de-la-Rosa, J.J.; Palomares-Salas, J.C.; Florencias-Oliveros, O. Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring. *Sensors* **2022**, *22*, 2928. <https://doi.org/10.3390/s22082928>

Academic Editor: Manuel Fuentes Conde

Received: 17 March 2022

Accepted: 7 April 2022

Published: 11 April 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

The increase in the installed photovoltaic (PV) power observed in recent years is expected to continue for both distributed and utility-scale systems [1]. With increasing penetration levels, grid stability and power quality can be affected by cloud-induced PV variability posing a series of technical challenges that have been the main focus of research in the topic during the last decade [2]. Techniques such as power curtailment or Battery Storage Energy Systems (BESS) have been widely used to minimize the high frequency PV power variability derived from cloud passage [3,4]. It has been demonstrated that forecasts in the range of seconds are necessary to take full advantage of these techniques. Concretely, power curtailment has proven to be efficient in smoothing upwards power ramps, but its application to the downward ones requires forecasts to perform curtailment before cloud arrival [5]. BESS based techniques can smooth both upwards and downwards ramps, but forecasts are also required for the optimized control of the charge/discharge cycles, which allows a reduction of battery capacity and an extension of its lifespan [6].

The term 'nowcasting' is frequently associated with ultra-short-term forecasts to clearly differentiate it from short-term forecasting, which involves longer prediction horizons and different applications. Namely, short-term forecasting is associated with horizons from tens of minutes to some hours, with applications in load dispatch, intra-day market, and

operational security of the electricity system [7]. Short-term forecasting is generally based on Numerical Weather Prediction (NWP) models and satellite observations with the goal of estimating the average cloud coverage over the period rather than the detection of individual clouds. On the other hand, nowcasting focuses on the range of seconds to few minutes, being used in real-time operation and control of PV systems and distribution feeders with significant PV penetration levels [8,9]. In this case, it is necessary to consider irradiance transitions generated by the passage of individual clouds, thereby requiring data sources capable of providing this information: satellite imagery, sky cameras, or irradiance sensor networks. However, satellite imagery has a limited spatial resolution and low sampling rate on the order of hundred of meters and several minutes, respectively. Thus, they are appropriate for the detection of atmospheric fronts that could cover the PV system in the next few minutes, but they are not particularly useful in the prediction of ramp events. Sky cameras, despite having a high acquisition rate, present difficulties in the translation of images to irradiance values [10]. Many studies focused on the reduction of errors derived from this translation, but they are generally higher than 20% Root Mean Square Error (RMSE) under partial cloud cover conditions [11–13].

Irradiance sensor networks are positioning themselves as a promising data source for nowcasting and short-term forecasting applications since they represent the simplest way to obtain spatial distributions of irradiance with a high sampling rate [10]. In this sense, Hoff and Perez stated that “regularly gridded networks of pyranometers” are the ideal data source for analyzing PV variability [14]. Chen et al. demanded a “dense sensor network dispersed over a wide area” as the best option to precisely capture cloud shadow features [15].

There are many examples of irradiance sensor networks in scientific literature, although they are typically designed for research purposes, with measurements stored in data loggers for an offline analysis. Table 1 includes some representative cases of these offline networks. For instance, the Oahu [16] and the Meltzip [17] networks have been used in many studies for different purposes, thanks to the data being available on their web sites. They share characteristics that are extensible to most of the offline networks: 1-s resolution, use of data-loggers, comparable areas and density of measurement points, and research focus. In Table 1, we referenced only two recent articles based on these networks for illustration purposes: data from the Oahu dataset applied to control of utility-scale PV plants [18], and data from the Melpitz dataset applied to model cloud advection [19]. The networks described in [20,21] has similar characteristics to the previous ones, although, in these cases, the pyranometers are arranged in a gridded layout.

Table 1. Irradiance sensor networks.

Ref.	Year	Sampling Period	N Pyran.	Area (Approx.)	Online?/Technology?
[22]	2013	40 ms	21	50 m × 50 m	No
[23]	2014	5 s	19	400 m × 500 m (5 buildings)	Yes/IEEE 802.15.4—ZigBee
[21]	2015	1 s	20	350 m × 280 m (gridded)	No
[24]	2016	10 s	3	200 m × 130 m	Yes/IEEE 802.15.4—NI WSN
[20]	2017	1 s	48	1.5 km × 1.5 km (gridded)	No
[25]	2017	1 s (avg 1 min)	24	42 km × 23 km	No
[26]	2018	0.5 s	16	15 m × 15 m (gridded)	Yes/IEEE 802.15.4—ZigBee
[27]	2019	1 min	2	15 km (distance)	Yes/WiFi+IoT
[28]	2019	1 s	5	200 m × 200 m (5 buildings)	Yes/LoRa
[29]	2020	5 min	10	100 m × 50 m	Yes/IEEE 802.15.4 MAC
[19]	2021	1 s	50	2 km × 2 km	No
[30]	2021	0.1 s	21	25 m × 50 m	No
[31]	2022	1 s (avg 1 min)	40	200 m × 200 km	Yes/Mobile network
[18]	2022	1 s	17	1 km × 1 km	No

The Singapore network used in [25] is also used as an offline data source, but, in this case, it has a more regional focus with spatial and temporal resolutions not appropriate for cloud passage events.

The above monitoring systems effectively fulfill the purpose for which they were conceived. However, in order to support real-life solutions for PV systems, irradiance sensor networks must be designed with different specifications. First, they should be able to capture and transmit data in real time or near real time. Second, the cost of the infrastructure must be economically justified. This limits the cost of the monitoring network in comparison with the PV system, as stated in [32]. In this sense, while wired networks are better in terms of latency, reliability, and data rates, they have penalties in deployment complexity, higher costs, and lower flexibility for adding new devices or moving existing ones. For instance, the wired irradiance network of the Tampere University of Technology described in [22] was able to capture 25 samples/s (sampling period of 40 ms) with 21 pyranometers connected to a CompactRIO data-acquisition system. The authors finally concluded that a sampling period of 100 ms “is sufficient for detecting even the fastest phenomena related to power generation with PV power plants”, which is the sampling frequency applied in subsequent studies based on this network [30,33]. Again, this deployment with advanced devices, complex infrastructure, and excess performance is justified by research purposes. Therefore, a wireless configuration implementing ordinary devices while meeting the necessary measurement specifications seems a more practical and cost-effective solution for real applications.

Examples of online irradiance Wireless Sensor Networks (WSN) with these characteristics are very scarce in scientific literature. There is specific research on the design of nodes for irradiance WSN [34,35], although no network is deployed in these investigations. In other cases, the potential of online irradiance WSN at regional scales is evaluated, but considering coarse spatial and temporal resolutions not adapted to cloud passage events [27,31]. In [29], the development of a rooftop irradiance WSN comprising 10 pyranometers is described, but again the 5-minutes sampling period is not adequate to deal with PV ramps.

As summary, there are only a few articles that describe real implementations of online irradiance WSN able to support control strategies for minimizing cloud-induced PV fluctuations. Achleitner et al. deployed an online sensor network in rooftops of neighboring buildings for forecasting purposes. The system was based on IEEE 802.15.4/ZigBee protocol, comprised 19 motes, and operated at a sampling period of 5 s [23]. The network described in [26] was also based in the 802.15.4/ZigBee protocol. In this case, it comprised 16 nodes regularly distributed over 15×15 m. The authors found network instability for sampling periods shorter than 500 ms and with a certain lack of synchronization. In [28], five nodes implementing LoRa were used to test a nowcasting method for “grid-friendly control” of PV systems. The network is conceived as a partial prototype of a theoretical monitoring system composed of two concentric circles of sensors with radii of 500 and 440 m, respectively, comprising a total of 48 pyranometers. The partial prototype of five sensors is designed to cover cloud motion directions from 0° to 60° North. The system described in [24] is designed to monitor a utility scale PV system using National Instruments (NI) devices. It cannot strictly be considered an irradiance monitoring network, as it is focused on power measurements and only three of the 12 motes include pyranometers but illustrates the feasibility of deploying Wireless Sensor Networks (WSN) with the required specifications in PV plants to provide additional information for PV plant control. Some of these studies will be used for comparison in Section 5.

The present article deals with the design and test of a wireless irradiance monitoring network with specifications comparable to the wired ones regarding sampling periods, stability, and synchronization. The article is structured as follows: Sections 2–5 and finalize with Section 6.

2. Materials and Methods

2.1. Wireless Protocols

The communication protocol is a fundamental element that strongly determines the design and specifications of a WSN. Since this WSN aims to support nowcasting applications for a wide range of PV systems, the design process will prioritize the achievement of high bandwidth and maximum spatial coverage as possible with reasonable power consumption and economic cost.

Bandwidth determines the amount of data that can be transmitted on the network per unit of time, thereby being a constraint for the maximum amount of motes for a specific sampling rate. In this sense, the selected wireless protocol aims to provide the maximum versatility in the amount of motes in the WSN and achievable sampling rate. On the other hand, coverage maximization pretends to provide large area connectivity using the minimum amount of wired parts, e.g., network devices that will require wired connection to a Local Area Network (LAN). Thus, the selection of the wireless protocol involves a trade-off between the two considerations, since high bandwidth and poor coverage are as detrimental as high range and inadequate bandwidth for the proposed objective. Table 2 is given to facilitate the comparison of main specifications of most commonly used wireless protocols.

Table 2. Comparative of main Wireless IoT communication protocol: Bluetooth, LoRa, ZigBee, and Wi-Fi. Simplification made from [36]: Table 2.

Technology	Bluetooth	LoRa	ZigBee	WiFi
Standard	IEEE 802.15.1	LoRaWAN	IEEE 802.15.4	IEEE 802.11 a/c/b/d/g/n
Frequency band	2.4–60 GHz	868/900 MHz	868/915 MHz; 2.4 GHz	2.4–60 GHz
Data rate	1–24 Mb/s	0.3–50 kb/s	40–250 kb/s	1 Mb/s–6.75 Gb/s
Typical range	10 m	30 km	10–100 m	100 m

Among these alternatives, Bluetooth was discarded due to its short range. As commented in the previous section, [26] found a maximum acceptable limit of 500 ms with 16 motes using ZigBee [26]. Since LoRa has lower data rate, it was also discarded. Finally, WiFi was the selected protocol for their range and data rate.

2.2. Application Layer Protocols

The Application Layer Protocol (ALP) is an abstraction layer that defines how applications should communicate. There are several ALP available for IoT messaging, but most commonly used ones are provided in Table 3.

Table 3. Comparison of main ALP for IoT messaging.

Specification \ Protocol	MQTT	CoAP	AMQP	HTTP
Transport layer	TCP	UDP	TCP	TCP
Min. header size	2 Bytes	4 Bytes	8 Bytes	26 Bytes
QoS/Reliability	3 Levels	2 Levels	2 Levels	Limited
M2M/IoT usage	Largest	Medium	High	Low

According to the information on the table, MQTT is a good candidate for ALP attending to two considerations: low overhead (header size) and high usage as M2M/IoT protocol. Low overhead is important since the required amount of information for data transmission is minimized, while the high IoT usage is a guarantee of good support of the protocol. Furthermore, 3 levels of QoS (Quality of Service) is an additional valuable feature for ensuring data reception. In this study, a QoS of 0 will be used, which is the minimum.

2.3. Development Board

The board selected for the development of the WSN is based on the ESP32 microcontroller from Espressif Systems, which includes features such as a dual-core 32-bits microprocessor running up to 240 MHz, 12-bit ADC channels, several digital interfaces such I2C, SPI, Serial and built-in Wi-Fi and Bluetooth connectivity, all of which are highly valuable for online WSN. As negative aspects, ESP32 microcontroller has some known issues, the most notable being the high noise and nonlinearity of the built-in ADC.

In order to overcome this issue, the manufacturer recommends connecting a 0.1 μF capacitor to the ADC pad and multi-sampling to reduce the noise profile [37]. The nonlinearity issue was also addressed in [38], and authors concluded that a calibration is compulsory for reliable results or using a narrow range where the ADC behavior can be considered to be linear. We conducted both procedures, but the observed improvement was not as relevant as expected. Furthermore, it was noticed that the noise profile changed with the sampling rate.

This issue can be solved using an external ADC if noticeable noise reduction is achieved. For this purpose, the ADS1115 IC was chosen as ADC because it provides up to 4 channels of 16-bit precision and up to 860 Samples Per Second (SPS) over I2C, with promising low noise profile and can be found in ready to use PCB boards.

Figure 1 shows the performance comparison for 200, 100, 50, and 10 ms of a sampling period of both ADCs. Each sampling period was tested for a duration of 60 s. A triangular signal of 2 s of periodicity was used for testing purposes, covering the expected pyranometer output from 700 W/m^2 to 800 W/m^2 , as a representation of a linear irradiance ramp of 100 W/m^2 per second. The behavior of the function generator was considered ideal. The embedded ESP32 ADC was calibrated with a linear regression for this range in order to compute noise, excluding nonlinearity response which is another drawback for the use of the built-in ADC. The ADS1115 was configured with a data rate of 128 SPS, which is capable of achieving 10 ms of sampling rate without overlapping samples.

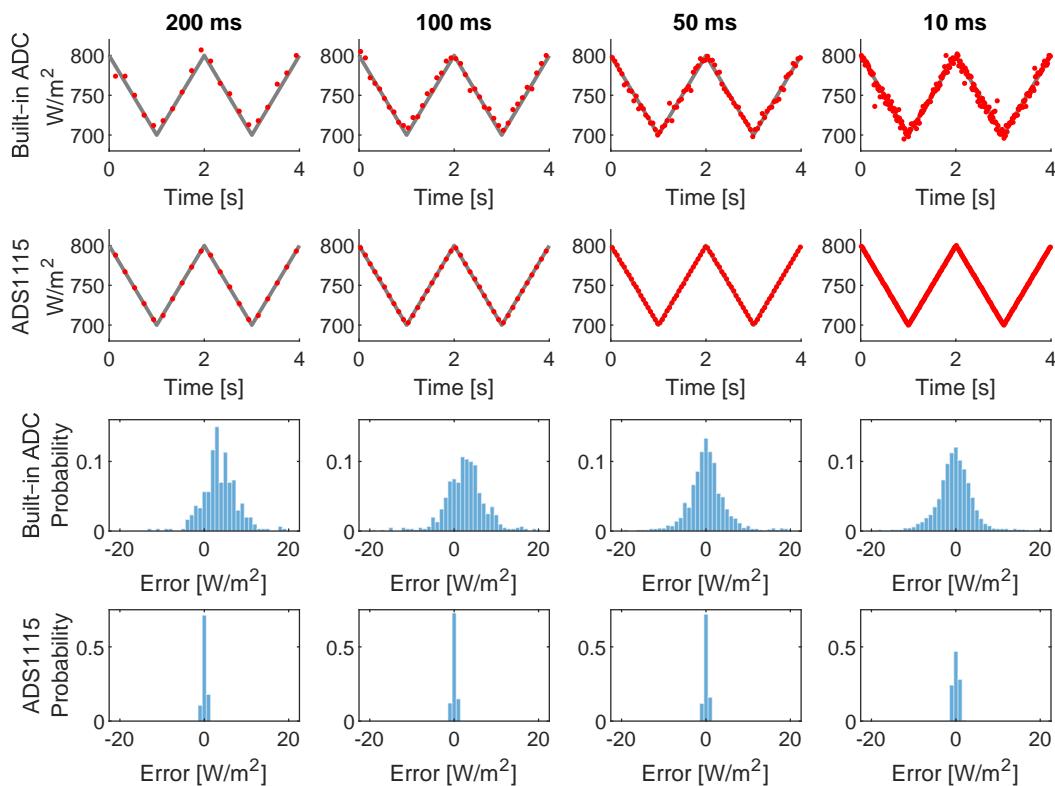


Figure 1. Comparison between ESP32 embed ADC and the external ADC ADS1115.

In Figure 1, each column represents the same sampling period, indicated at the top text. The first two rows correspond to the four seconds of the test, the upper one corresponds to the built-in ADC as labelled on the right side, and the second row corresponds to the ADS1115. The gray lines represent the ideal input waveform and the red dots the sampled values from ADC. Error histograms with 1 W/m^2 of bin size are shown following the same organization in the last 2 rows.

The noise reduction provided by the ADS1115 over built-in ADC from histograms in Figure 1 is noticeable. The noise profile of the embedded ADC can be assumable for a single irradiance monitoring sensor, but it is a major issue when the 16 signals captured from motes are processed by cloud motion estimation algorithms. Based on the previously mentioned and the noise reduction achieved with the inexpensive external ADC, authors consider that its usage is justified.

2.4. Sensor Selection

Pyranometers can be classified into two main types according to their working principle: thermopiles and photodiodes. While thermopile based pyranometers have better spectral response than photodiode ones, they are more expensive and present longer response times. Photodiode based pyranometers have a response time on the order of milliseconds, while thermopile ones usually stand on the order of seconds. These differences make the photodiodes based pyranometers adequate for a low cost and high sample rate irradiance monitoring network. Based on the above statement, a good candidate sensor for monitoring solar irradiance is the SP-214, which is a photodiode pyranometer from Apogee Instruments, Inc. Logan, USA. Its main specifications are given in Table 4.

Table 4. Main specifications of the pyranometer SP-214 (Apogee Instruments, Inc., Logan, UT, USA).

Specification	Value
Power supply range	7–24 V DC
Output range	4–20 mA
Calibration factor	125 W/m^2 per mA + 4 mA offset
Sensibility	$0.008 \text{ mA per W/m}^2$
Measurement range	$0\text{--}2000 \text{ W/m}^2$
Nonlinearity	<1% (up to 2000 W/m^2)
Response time	<1 ms

2.5. Mote Prototype

The mote was built by connecting the pyranometer to the external ADC (ADS1115), and the latter to the ESP32. The irradiance sensor and the voltage regulator are powered using an external 15V AC-DC power supply with additional voltage regulations inside the prototype box. The voltage regulator is a DC-DC step down, providing 5V at the output, which is acceptable to power the ADS1115 and ESP32 boards. Figure 2 illustrates the connections among the different components of the mote.

The electronic circuits of the prototype were placed inside a box (Figure 3a), except for the irradiance sensor, which was placed outside connected by a 5 m cable (Figure 3b).

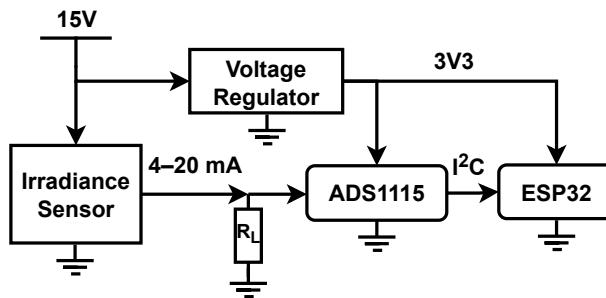


Figure 2. Electronics box diagram of one mote of the WSN.

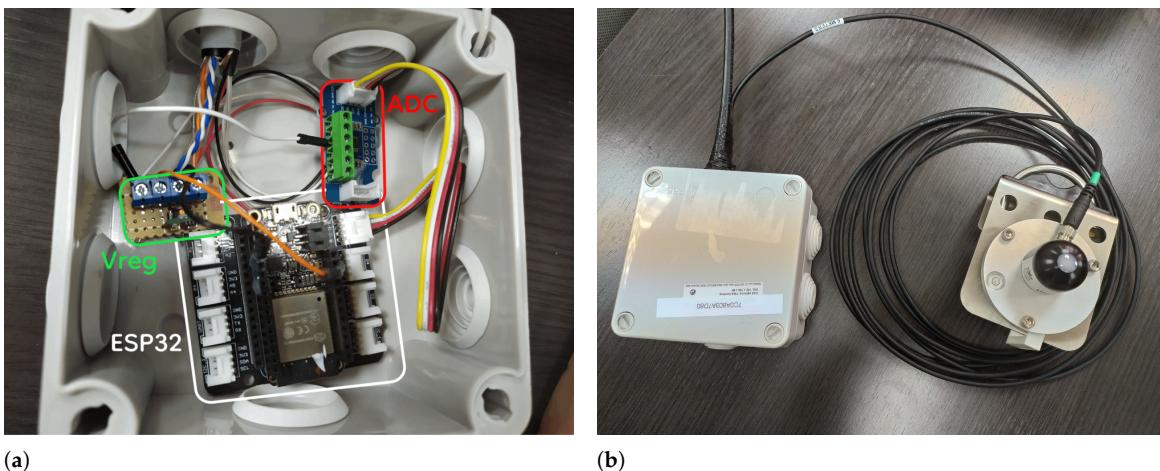


Figure 3. Inside and outside looking of the mote prototype. (a) Elements inside the box with Voltage Regulator (marked as Vreg); (b) box and pyranometer.

For the load resistance, R_L , a $150\ \Omega$ value resistor, was used to convert the 4–20 mA output from pyranometer to voltage ranging from 0.6 to 3 V. Based on the electronic diagram of Figure 2, the ADS1115 input impedance creates a current divider, and its effects should be quantified.

Texas Instruments characterize the typical ADS1115 IC input impedance in $6\ M\Omega$ for the common-mode, with a sensibility of $125\ \mu V/count$ and 8 SPS. Texas Instruments does not provide electrical characterization for data rates different to 8 SPS. This study tested the ADS1115 with 8 SPS and 128 SPS, and no difference was found. Hence, it can be assumed for current divider estimation that the input impedance stays on the order of $6\ M\Omega$. On this basis, the deviation of voltage drop in R_L should be much less than 0.01%, which is small enough to be assumed with the benefit of no extra circuitries like operational amplifiers in voltage follower configuration.

2.6. Server

The WSN requires a server and a software stack to perform the data processing and store the irradiance values sent by the motes. The software was intended to be lightweight and the bare minimum. Initially, the software stack consists of an MQTT Broker, databases with agents for processing and pushing data to databases. Mosquitto is the software chosen as an MQTT Broker due to its extended usage and its open source license. For data storage, two databases were tested: InfluxDB, which is a time series database, and MariaDB, which is a relational one, are both open source.

Some agent is needed between the MQTT Broker and the databases. For that purpose, the Telegraf agent was chosen for collecting data from the MQTT broker, processing and pushing them into InfluxDB (a simplified configuration file is provided in Code 1,

Appendix A), while, for storing data in the MariaDB, the Node-RED and the data flow shown in Figure 4 were used.

Figure 5 offers a visual description of the network topology initially used.

The hardware used in this study was an HP Proliant MicroServer Gen8 (HP Inc., Palo Alto, CA, USA) with a XEON E3160L and 12 GiB of RAM at 1333 MHz. The required software was installed on virtualized Debian 11 running on a LXC container in Proxmox VE 7.1. from Proxmox Server Solutions GmbH (Wien, Austria). Some performance loss could be expected due to virtualization technology.

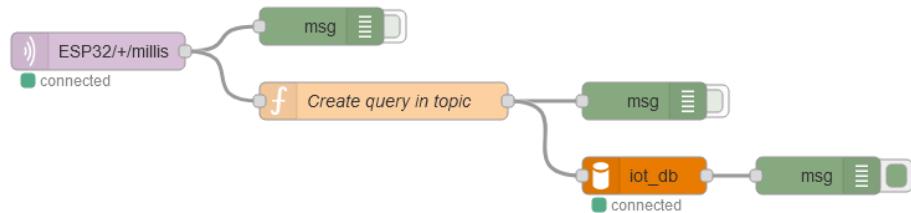


Figure 4. Node-RED data flow.

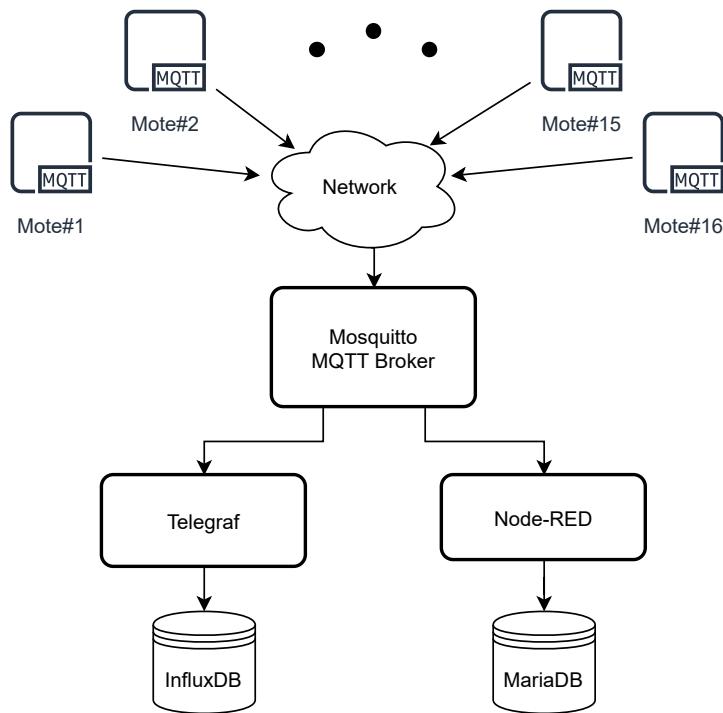


Figure 5. Initial network topology. Black dots refer to other motes devices.

2.7. Performance Test Design

The performance test is focused on characterizing the network stability, data synchronization, and storage process efficiency. To achieve this goal, the network motes were programmed using timer interruption at a fixed rate to prevent time drifting due to processing time. The interruption period can be changed remotely using a specific MQTT topic that reprograms the timer according to the requested period. In each timer interruption, the microcontroller sends Unix time with millisecond precision, providing a timestamp to contextualize the samples. The capability of each mote to perform sampling at a fixed rate

can be assessed by computing the vector D , defined as the differences of sent times (T) of consecutive measurements ($k, k - 1$) from one mote:

$$D[k - 1] = T[k] - T[k - 1] \forall k \in [1, 2, 3...n] \quad (1)$$

On the server side, each datum is stored with the reception timestamp with the precision of milliseconds. Similarly to Equation (1), the reception stability can be analyzed using time differences of a reception timestamp.

Finally, packet loss ratio, defined as the amount of packets not received over the expected, is another relevant aspect to characterize the network stability. Calling T_{test} the test time for the sampling period T_s , the number of expected packets per device, p_e , can be calculated as:

$$p_e = \frac{T_{test}}{T_s} \quad (2)$$

Let p_r be the amount of packet received from one device during T_{test} time and sampling period T_s , the packet loss ratio, p_l , can be defined as follows:

$$p_l(\%) = \frac{p_e - p_r}{p_e} \cdot 100 \quad (3)$$

As stated above, operational data for PV plants and nowcasting techniques require sub-second sampling. Based on this, the performance test was designed to analyse the following sampling periods: 500, 300, 200, 100, 50, 25, and 10 ms, with a duration of 600 s per sampling period.

Since ESP32 has the capability to perform time synchronization using Simple Network Time Protocol (SNTP) against a NTP server [39], this functionality will be used for a timestamp each datum with absolute time reference for better traceability. In this case, the Masterclock GMR5000 (Figure 6) has been used as a precision local NTP server for accurate characterization purposes, but a public or another kind of local NTP server could be used. Each mote performs a NTP synchronization after the boot up, and sets up the timer for interruptions with the UTC second changes. Under normal operation mode, NTP resynchronization is done once every 10 min to avoid noticeable time drift of the RTC timer.



Figure 6. GMR5000 (from Masterclock Inc., St Charles, MO, USA) as an NTP local server used for time syncing.

In the preliminary implementations of the performance test, it was evident that the Node-RED and MariaDB branch did not work as expected: data ingestion demanded an excessively long time at sampling periods shorter than 200 ms. Consequently, for the sake of simplicity in testing and presentation of results, this branch was discarded and hence the topology shown in Figure 7 was used in the following sections.

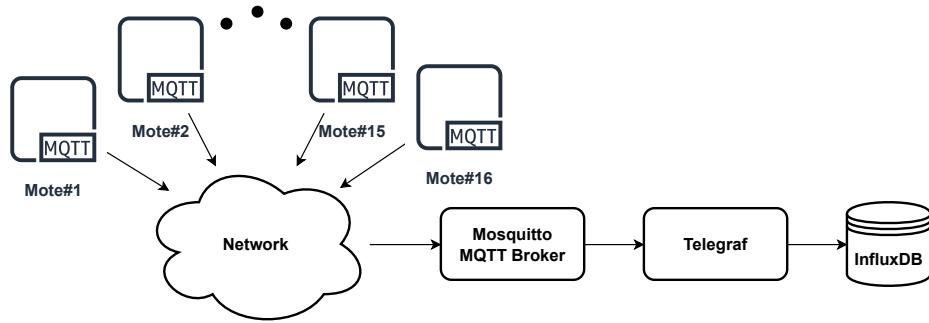


Figure 7. Final network topology.

3. Network Performance Test Results

As stated above, sampling stability, reception stability, and packet loss ratio will be analyzed. The results are presented grouped by sampling period, providing a characterization of the performance of the WSN for each working state. Figure 8 corresponds to the sampling histograms of 16 motes.

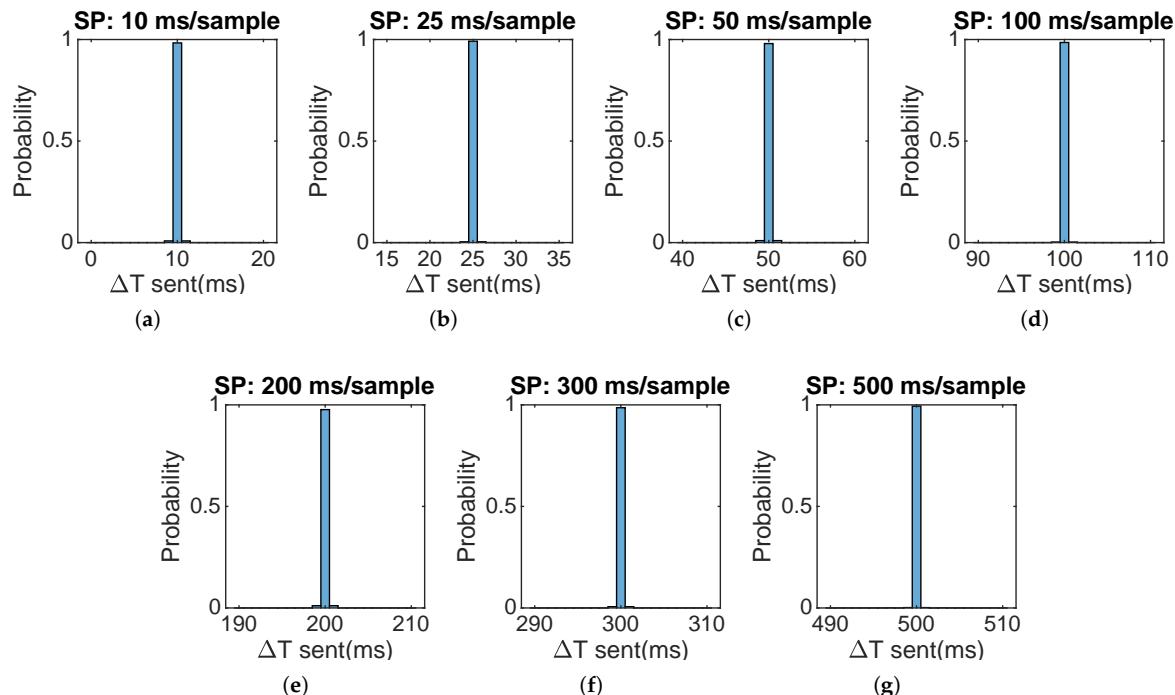


Figure 8. Sampling histograms for each sampling period tested. Each Sampling Period (SP) is indicated in the histogram title (a–g).

It can be inferred from the histograms of Figure 8 that the WSN motes present an excellent sampling behavior. For each sampling period, a mean deviation of 0 ms is observed thanks to the timer interrupt that avoids time drifting.

A good mote sampling stability does not imply reception stability, most especially in wireless devices. Following the procedure described in the previous section, the reception stability was analyzed based on the server reception time differences between two consecutive packets for the same device. Figure 9 shows the histograms associated with this analysis by aggregating the individual results of the 16 motes for each sampling period.

The histogram associated with the sampling period of 10 ms in Figure 9 shows a bimodal distribution. From that distribution, it can be inferred that delayed packets

overlap in time with the next ones; hence, it cannot be assumed that the reception time is representative of the sample time when sampling periods are in this range.

For all the other sampling period histograms, the reception time deviation stays in a range of ± 10 ms, with the highest peak at the sampling period interval bin and almost symmetrical distribution considering a bin size of 1 ms. As a special particularity, the highest probability to receive the data at requested interval ± 0.5 ms is given for a sampling period of 50 ms, followed by 25 ms. These results can be counter-intuitive since it reflects a better performance at these sampling periods than at longer sampling periods, when the network is supposed to be less congested.

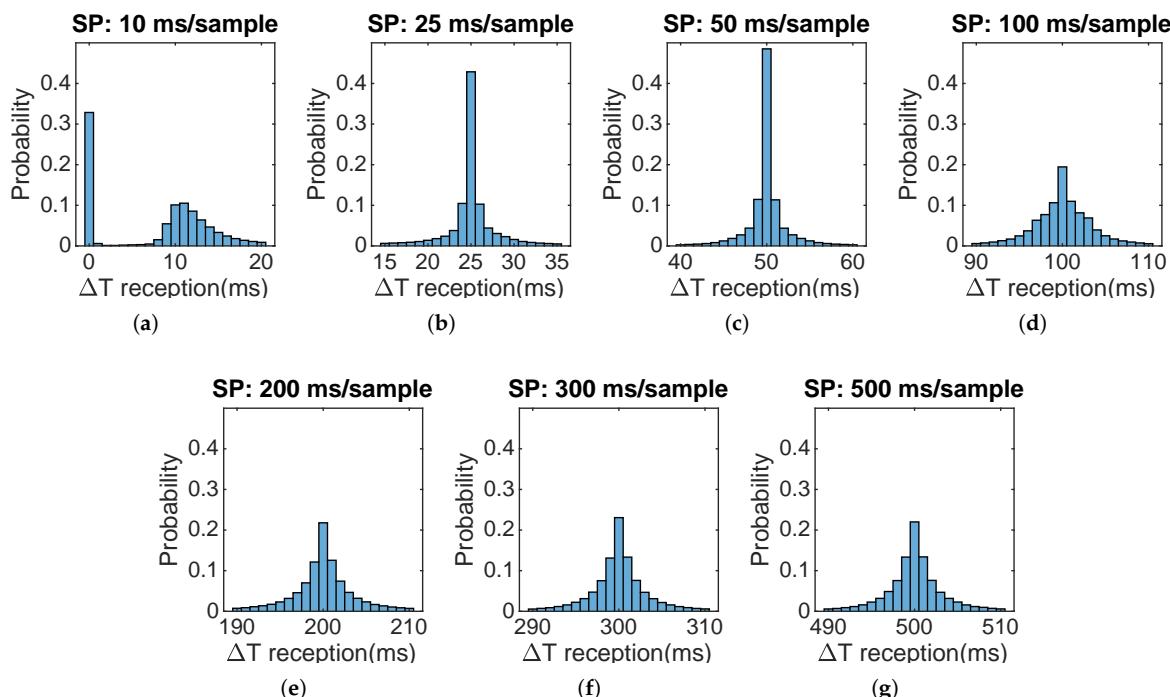


Figure 9. Histogram of reception time difference for each sampling period, indicated in the histogram title (a–g).

Another important performance aspect to analyze is the packet loss ratio. This ratio provides a quantization of packets that did not reach the end of the data flow, which is in this case the database. The cause of the packet losses could be diverse: packet not sent by the mote, mote disconnections, packet lost by the WiFi network, or even data not processed properly by the server. Figure 10 shows packet loss ratio versus sampling period.

Attending to the Figure 10, no correlation was found between sampling period and packet losses. Packet loss ratio was kept under 0.45% for all tested sampling periods, thereby being a low value with no relevant impact for WSN purposes.

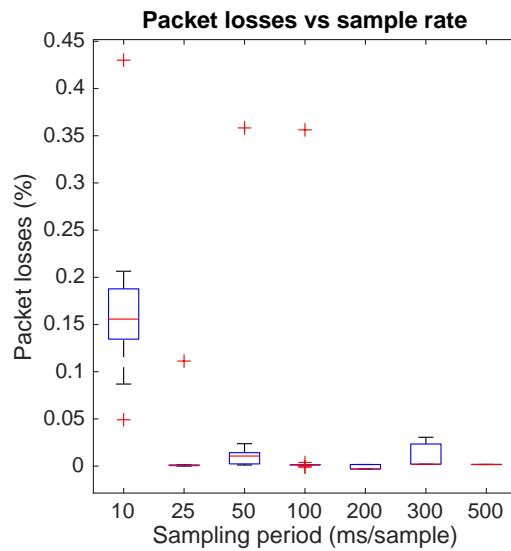


Figure 10. Packet loss ratio versus tested sampling periods.

4. Irradiance Field Results

The developed WSN was deployed at the rooftop of the University building in a regular 4-by-4 gridded configuration with a minimum inter-sensor distance of 5 m, covering an area of 15×15 m, as can be seen in Figure 11. The red circles of the figure indicate the pyranometers' positions, while the blue one locates the router and power supply.

A monitoring campaign was done using the presented distribution on 10 February 2022 under partial cloud cover conditions. For this campaign, a sampling period of 50 ms was used—half of the 100 ms period sufficient to capture the fastest irradiance changes [22,33]—to offer a comparative of longer sampling periods. The acquired GHI time series' values include several interesting cloud passages for analysis. One of them is represented in the 20 s time-series shown in Figure 12, which started at 12:40:22 UTC time.



Figure 11. WSN deployed at the rooftop of the University building. Red circles indicate pyranometers, and the blue circle locates the position of the router and AC-DC power supply.

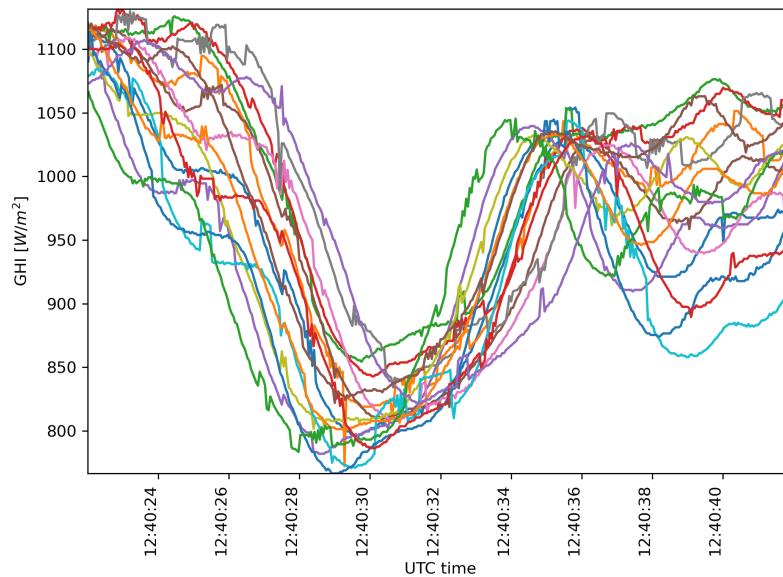


Figure 12. 20 s of 16 irradiance time series captured from WSN on 10 February 2022 starting at 12:40:22 UTC time.

The same irradiance values can be represented in a 4-by-4 matrix for each sampling time, representing the spatial distribution. This technique provides a visual representation of the irradiance field evolution, allowing a better comparison between sampling periods. Using the previous 20 s irradiance time-series, the 2D representation is shown in Figure 13. Snapshots for sampling periods of 1000, 500, 200, and 100 ms are also represented using a subsampling technique to offer a visual comparison of the evolution for several sampling periods.

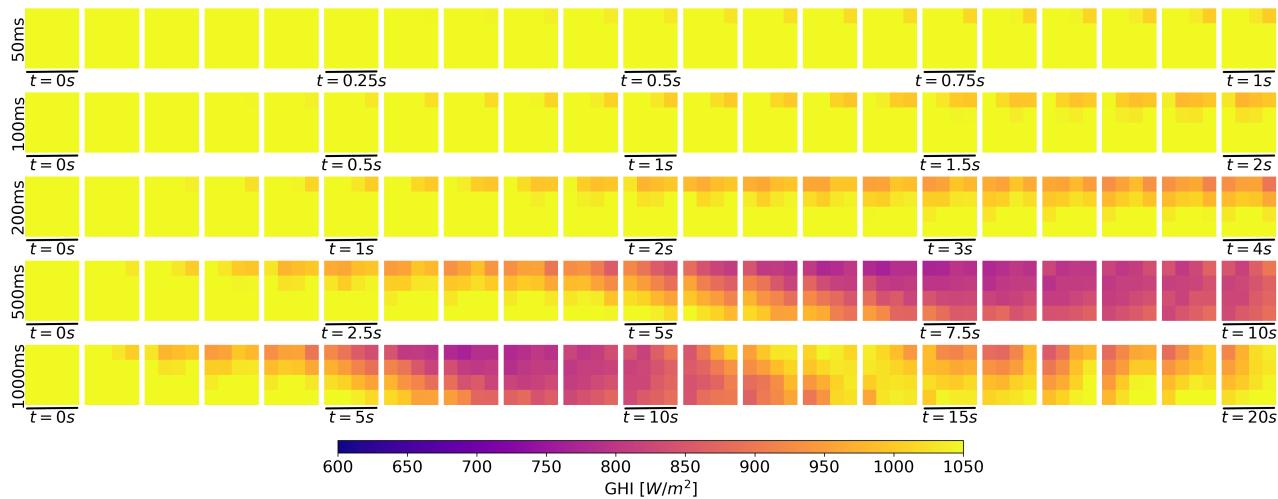


Figure 13. Snapshots evolution from data represented in Figure 12. Each row represents the evolution at different sampling periods.

Note that, for shorter sampling periods, the irradiance field evolution is captured with high detail but requires more snapshots to capture a complete ramp.

The continuation of the above time series with a total duration of one minute is shown in Figure 14. Snapshots evolution using these data and downscaling to a sampling period of 500 ms can be seen in Figure 15.

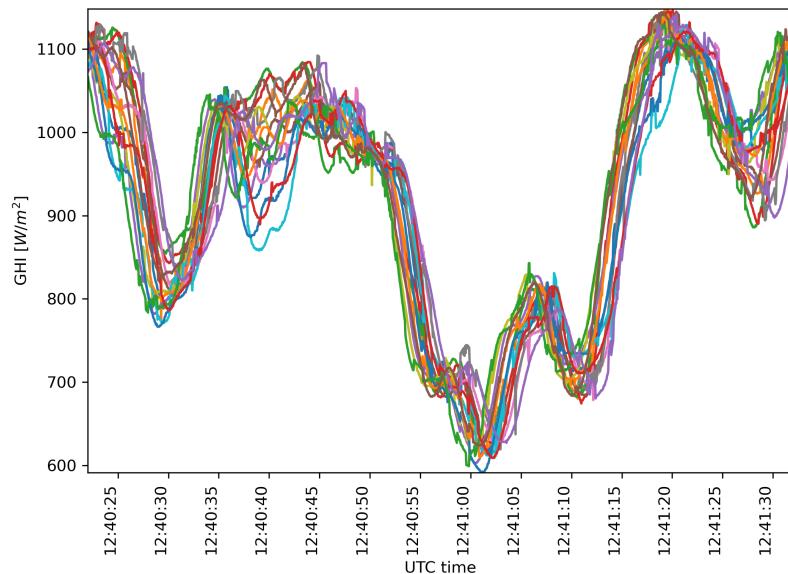


Figure 14. 60 s of 16 irradiance time series captured from WSN on 10 February 2022 starting at 12:40:22 UTC time.

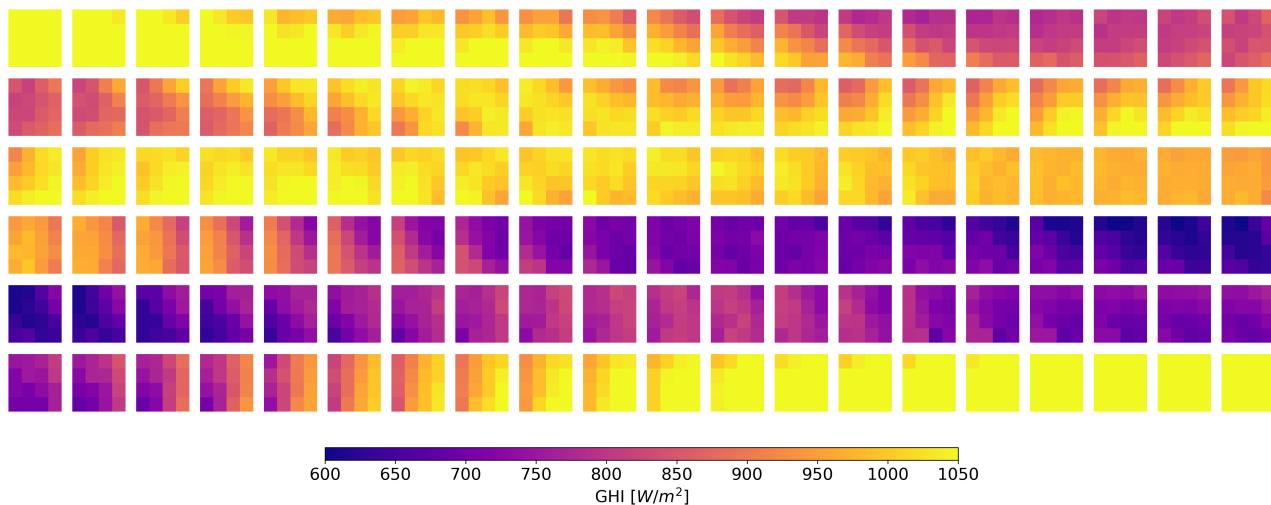


Figure 15. 60 s of snapshots evolution at 500 ms from time series shown in Figure 14 acquired with the designed WSN. Each row represents 10 seconds of the evolution.

The stated results reveal the potential of the developed WSN to online monitor the irradiance field at fast sampling periods. This makes this WSN a valuable data source for PV power plants with the benefits in costs of a wireless alternative and for research to apply cloud shadow motion algorithms and nowcasting techniques.

5. Discussion

This section aims to contextualize the results of the previous two sections in relation to other studies. Assuming a certain quality of pyranometers, the key factor in evaluating the usefulness of an irradiance sensor network for nowcasting applications is the sampling period. In this aspect, the results described in Section 3 illustrating adequate performance for 50 ms—even 25 ms—can only be compared to the 40 ms in [22], and significantly outperforms the sampling rates of the WSN summarized in Table 1. In any case, the WSN

is able to sample at 100 ms, which which is considered sufficient to describe the fastest changes of irradiance [22,40].

Another fundamental aspect is the capability of the network of supporting cloud motion estimation algorithms, which is critical information for irradiance nowcasting systems. Espinosa-Gavira et al. defined the relationship between sampling period, sensing area, and cloud shadow speed in [41]. This and other studies established 30 m/s as an upper limit of cloud shadow speeds for testing the operation of PV systems, since higher speeds have an extremely low occurrence [40]. Applying the equations, a cloud passage at the maximum expected speed, 30 m/s, will be registered in 5 snapshots using a 15×15 m gridded configuration and a sampling period of 100 ms, which should be enough to support a nowcasting system. In this sense, larger area networks and/or lower cloud speeds will be registered in more snapshots. In summary, a sampling period of 100 ms should also be sufficient for most of the monitoring systems if there are cloud motion estimation algorithms.

The WSN showed great stability of sampling and reception with a very low packet loss ratio. The motes were kept in synchronization via the NTP server, avoiding the time drift of the RTC, and enabling the contextualization of samples with absolute timestamping. It would be interesting to compare these results with other studies, but this type of characterization is generally neglected in similar research. In this sense, it would be desirable that further studies incorporate characterizations of sampling, reception, synchronicity, or packet losses to determine which is the most efficient technology for this problem.

The use of WSN to provide additional information for PV system control has proven to be a feasible solution using NI-WSN [24] or ZigBee [42], although, in these cases, the networks were mainly focused on power measurements. According to the results in [26], the application of these technologies—both based in the IEEE 802.15.4 standard—to irradiance measurement would encounter problems in achieving sampling periods of 100 ms and the required level of synchronization. In fact, in [24], the IEEE 1588 Precision Time Protocol (PTP) standard is used to guarantee synchronization, with a consequent increase in system complexity, but maintaining a 10 s sampling period. LoRaWAN could represent another communication option, but its maximum data rate is below the IEEE 802.15.4 standard, being only able to achieve sub-second sampling under very favorable conditions [43]. In this framework, the use of WiFi with NTP synchronization represents an adequate option to achieve the requirements of an irradiance monitoring system for nowcasting applications, with options of scalability by adding new routers without performance penalties.

The ESP32 has demonstrated to be an IoT device capable of performing outdoor monitoring using WiFi [44,45]. For two weeks, the WSN was deployed on the university building rooftop under variable weather conditions, showing no appreciable difference in performance.

6. Conclusions

This study deals with the design and testing of an online wireless irradiance sensor network capable of providing real-time data to support PV systems operations and irradiance nowcasting. The WiFi protocol has been chosen with the objective of maximizing spatial coverage with sufficient bandwidth to achieve the most demanding requirements of research irradiance monitoring networks, while providing flexibility to add new motes or spatially move existing ones without economic impact. The designed wireless network proved its capability to achieve sampling periods up to 25 ms with good coordination and very low packet loss ratio, thus clearly outperforming the period of 100 ms that is considered enough to detect the fastest expected irradiance phenomena. Irradiance data of a monitoring campaign was spatially represented, showing that the system was able to capture detailed features of the irradiance field and its evolution. It was also discussed how the network measurement capabilities should be enough to capture even the fastest clouds and to be adapted to different extensions. The availability of this information with a low latency makes this monitoring system a valuable tool for a wide range of PV systems

control and future research. Analysis of the mote side showed that the devices have enough computing power to overpass the most demanding test, as shown in Figure 8. On the server side, samples have a good behavior for a sampling period of 25 ms with good stability and packet loss ratio lower than 0.45% Based on the test conducted and results, the designed WSN is capable of achieving comparable specification to a state-of-the art irradiance monitoring network with the advantages in costs of the wireless technology.

Future work will improve the designed WSN by replacing the external power supply for a small PV panel and a battery pack to provide fully autonomous wireless features. Data collected by the WSN will be used to apply cloud motion estimation algorithms, nowcasting techniques, and how collaborative nearby irradiance networks could improve forecasting skills.

Author Contributions: M.J.E.-G. and A.A.-P. designed and tested the WSN, wrote the article, processed the data acquired from the WSN, generated images and tables, and deployed the WSN for the monitoring campaign J.M.S.-F. provided a contextualization of IoT protocols and managed the order of sensors and electronics. J.J.G.d.-I.-R. reviewed the writing and the English expressions A.A.-P. and J.J.G.d.-I.-R. contributed to the funding acquisition in the framework of a national research project. J.C.P.-S. and O.F.-O. performed the statistical analysis of WSN performance. All authors have read and agreed to the published version of the manuscript.

Funding: This work was supported by the Spanish Ministry of Science and Innovation Grant No. PID2019-108953RB-C21. The authors would like to thank the Andalusian Government for funding the Research Unit PAIDI-TIC-168.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

Appendix A

Code 1: Simplified Telegraf configuration file used for performance tests.

```
[agent]
interval = "5s"
round_interval = true
metric_buffer_limit = 10000
flush_buffer_when_full = true
collection_jitter = "0s"
flush_interval = "1s"
flush_jitter = "0s"

[[outputs.influxdb]]
urls = ["http://127.0.0.1:8086"]
database = "influx"
precision = "ms"
timeout = "5s"

[[inputs.mqtt_consumer]]
servers = ["tcp://127.0.0.1:1883"]
topics = ["ESP32/#"]
data_format = "value"
```

References

- IEA. Snapshot of Global PV Markets 2021. pp. 1–21. Available online: www.Iea-Pvps.Org (accessed on 14 March 2022).
- Eltawil, M.; Zhao, Z. Grid-connected photovoltaic power systems: Technical and potential problems-A review. *Renew. Sustain. Energy Rev.* **2010**, *14*, 112–129. [[CrossRef](#)]
- Sukumar, S.; Marsadek, M.; Agileswari, K.; Mokhlis, H. Ramp-rate control smoothing methods to control output power fluctuations from solar photovoltaic (PV) sources-A review. *J. Energy Storage* **2018**, *20*, 218–229. [[CrossRef](#)]
- Shivashankar, S.; Mekhilef, S.; Mokhlis, H.; Karimi, M. Mitigating methods of power fluctuation of photovoltaic (PV) sources—A review. *Renew. Sustain. Energy Rev.* **2016**, *59*, 1170–1184. [[CrossRef](#)]

5. Chen, X.; Du, Y.; Wen, H.; Jiang, L.; Xiao, W. Forecasting-Based Power Ramp-Rate Control Strategies for Utility-Scale PV Systems. *IEEE Trans. Ind. Electron.* **2019**, *66*, 1862–1871. [[CrossRef](#)]
6. Chen, X.; Du, Y.; Xiao, W.; Lu, S. Power ramp-rate control based on power forecasting for PV grid-tied systems with minimum energy storage. In Proceedings of the IECON 2017—43rd Annual Conference of the IEEE Industrial Electronics Society, Beijing, China, 29 October–1 November 2017; pp. 2647–2652. [[CrossRef](#)]
7. Ahmed, R.; Sreeram, V.; Mishra, Y.; Arif, M. A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. *Renew. Sustain. Energy Rev.* **2020**, *124*, 109792. [[CrossRef](#)]
8. Theo, W.L.; Lim, J.S.; Ho, W.S.; Hashim, H.; Lee, C.T. Review of distributed generation (DG) system planning and optimisation techniques Comparison of numerical and mathematical modelling methods. *Ren. Sustain. Energy Rev.* **2017**, *67*, 531–573. [[CrossRef](#)]
9. Samu, R.; Calais, M.; Shafiullah, G.; Moghbel, M.; Shoeb, M.A.; Nouri, B.; Blum, N. Applications for solar irradiance nowcasting in the control of microgrids: A review. *Renew. Sustain. Energy Rev.* **2021**, *147*, 111187. [[CrossRef](#)]
10. Yang, D.; Kleissl, J.; Gueymard, C.A.; Pedro, H.T.C.; Coimbra, C.F.M. History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Sol. Energy* **2018**, *168*, 60–101. [[CrossRef](#)]
11. Alonso-Montesinos, J.; Batllés, F.; Portillo, C. Solar irradiance forecasting at one-minute intervals for different sky conditions using sky camera images. *Energy Convers. Manag.* **2015**, *105*, 1166–1177. [[CrossRef](#)]
12. Scolari, E.; Sossan, F.; Haure-Touzé, M.; Paolone, M. Local estimation of the global horizontal irradiance using an all-sky camera. *Sol. Energy* **2018**, *173*, 1225–1235. [[CrossRef](#)]
13. Schmidt, T.; Kalisch, J.; Lorenz, E.; Heinemann, D. Evaluating the spatio-temporal performance of sky-imager-based solar irradiance analysis and forecasts. *Atmos. Chem. Phys.* **2016**, *16*, 3399–3412. [[CrossRef](#)]
14. Hoff, T.; Perez, R. Quantifying PV power Output Variability. *Sol. Energy* **2010**, *84*, 1782–1793. [[CrossRef](#)]
15. Chen, X.; Du, Y.; Lim, E.; Wen, H.; Yan, K.; Kirtley, J. Power ramp-rates of utility-scale PV systems under passing clouds: Module-level emulation with cloud shadow modeling. *Appl. Energy* **2020**, *268*, 114980. [[CrossRef](#)]
16. National Renewable Energy Laboratory (NREL). Oahu Solar Measurement Grid. 2021. Available online: <https://midcdmz.nrel.gov/apps/sitehome.pl?site=OAHUGRID> (accessed on 17 December 2021).
17. World Data Center for Climate (WDCC) at DKRZ. HD(CP)2 Short Term Observation Data of Pyranometer Network, HOPE-Melpitz Campaign by TROPOS. 2021. Available online: https://cera-www.dkrz.de/WDCC/ui/cerasearch/entry?acronym=HOPM_TROP_PYRNET (accessed on 17 December 2021).
18. Julien, S.; Sajadi, A.; Hodge, B.M.S. Hierarchical Control of Utility-Scale Solar PV Plants for Mitigation of Generation Variability and Ancillary Service Provision. *IEEE Trans. Sustain. Energy* **2022**. [[CrossRef](#)]
19. Ranalli, J.; Peerlings, E.E. Cloud advection model of solar irradiance smoothing by spatial aggregation. *J. Renew. Sustain. Energy* **2021**, *13*, 033704. [[CrossRef](#)]
20. Monger, S.H.; Morgan, E.R.; Dyreson, A.R.; Acker, T.L. Applying the kriging method to predicting irradiance variability at a potential PV power plant. *Renew. Energy* **2016**, *86*, 602–610. [[CrossRef](#)]
21. Schenk, H.; Hirsch, T.; Wittmann, M.; Wilbert, S.; Keller, L.; Prahl, C. Design and Operation of an Irradiance Measurement Network. *Energy Procedia* **2015**, *69*, 2019–2030. [[CrossRef](#)]
22. Torres Lobera, D.; Mäki, A.; Huusari, J.; Lappalainen, K.; Suntio, T.; Valkealahti, S. Operation of TUT solar pv power station research plant under partial shading caused by snow and buildings. *Int. J. Photoenergy* **2013**, *2013*, 837310. [[CrossRef](#)]
23. Achleitner, S. SIPS: Solar Irradiance Prediction System. In Proceedings of the IPSN-14 Proceedings of the 13th International Symposium on Information Processing in Sensor Networks, Berlin, Germany, 15–17 April 2014; pp. 225–236. [[CrossRef](#)]
24. Moreno-García, I.M.; Palacios-García, E.J.; Pallares-Lopez, V.; Santiago, I.; Gonzalez-Redondo, M.J.; Varo-Martinez, M.; Real-Calvo, R.J. Real-Time Monitoring System for a Utility-Scale Photovoltaic Power Plant. *Sensors* **2016**, *16*, 770. [[CrossRef](#)]
25. Yang, D. On adding and removing sensors in a solar irradiance monitoring network for areal forecasting and PV system performance evaluation. *Sol. Energy* **2017**, *155*, 1417–1430. [[CrossRef](#)]
26. Espinosa-Gavira, M.J.; Agüera-Pérez, A.; de la Rosa, J.J.G.; Palomares-Salas, J.C.; Sierra-Fernández, J.M. An online low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV systems. *Sensors* **2018**, *18*, 3405. [[CrossRef](#)] [[PubMed](#)]
27. Pereira, R.I.; Jucá, S.C.; Carvalho, P.C. IoT embedded systems network and sensors signal conditioning applied to decentralized photovoltaic plants. *Measurement* **2019**, *142*, 195–212. [[CrossRef](#)]
28. Chen, X.; Du, Y.; Lim, E.; Wen, H.; Jiang, L. Sensor network based PV power nowcasting with spatio-temporal preselection for grid-friendly control. *Appl. Energy* **2019**, *255*, 113760. [[CrossRef](#)]
29. Pal, A. EPIC-RoofNet: A Sensor Network Testbed for Solar Irradiance Measurement and Analysis. In Proceedings of the 2020 16th International Conference on Distributed Computing in Sensor Systems (DCOSS), Marina del Rey, CA, USA, 25–27 May 2020; pp. 147–150. [[CrossRef](#)]
30. Lappalainen, K.; Valkealahti, S. Experimental study of the maximum power point characteristics of partially shaded photovoltaic strings. *Appl. Energy* **2021**, *301*, 117436. [[CrossRef](#)]
31. Lorenz, E.; Guthke, P.; Dittmann, A.; Holland, N.; Herzberg, W.; Karalus, S.; Müller, B.; Braun, C.; Heydenreich, W.; Saint-Drenan, Y.M. High resolution measurement network of global horizontal and tilted solar irradiance in southern Germany with a new quality control scheme. *Sol. Energy* **2022**, *231*, 593–606. [[CrossRef](#)]

32. Mazzola, S.; Vergara, C.; Astolfi, M.; Li, V.; Perez-Arriaga, I.; Macchi, E. Assessing the value of forecast-based dispatch in the operation of off-grid rural microgrids. *Renew. Energy* **2017**, *108*, 116–125. [[CrossRef](#)]
33. Lappalainen, K.; Valkealahti, S. Recognition and modelling of irradiance transitions caused by moving clouds. *Sol. Energy* **2015**, *112*, 55–67. [[CrossRef](#)]
34. Pazikadin, A.R.; Rifai, D.; Ali, K.; Mamat, N.H.; Khamsah, N. Design and implementation of fuzzy compensation scheme for temperature and solar irradiance wireless sensor network (Wsn) on solar photovoltaic (pv) system. *Sensors* **2020**, *20*, 6744. [[CrossRef](#)]
35. Rocha, A.B.d.; Fernandes, E.d.M.; Santos, C.A.C.d.; Diniz, J.M.T.; Junior, W.F.A. Development of a Real-Time Surface Solar Radiation Measurement System Based on the Internet of Things (IoT). *Sensors* **2021**, *21*, 3836. [[CrossRef](#)]
36. Ray, P.P. A survey on Internet of Things architectures. *J. King Saud Univ.-Comput. Inf. Sci.* **2018**, *30*, 291–319. [[CrossRef](#)]
37. Analog to Digital Converter - Espressif ESP-IDF Programming Guide for ESP32. Available online: <https://docs.espressif.com/projects/esp-idf/en/v4.2/esp32/api-reference/peripherals/adc.html> (accessed on 16 October 2021).
38. Carducci, C.G.C.; Monti, A.; Schraven, M.H.; Schumacher, M.; Mueller, D. Enabling ESP32-based IoT Applications in Building Automation Systems. In Proceedings of the 2019 IEEE International Workshop on Metrology for Industry 4.0 and IoT (MetroInd 4.0 and IoT), Naples, Italy, 4–6 June 2019; pp. 306–311. [[CrossRef](#)]
39. System Time—SNTP Time Synchronization—Espressif ESP-IDF Programming Guide for ESP32. Available online: https://docs.espressif.com/projects/esp-idf/en/latest/esp32/api-reference/system/system_time.html#sntp-time-synchronization (accessed on 10 January 2021).
40. Lappalainen, K.; Valkealahti, S. Analysis of shading periods caused by moving clouds. *Sol. Energy* **2016**, *135*, 188–196. [[CrossRef](#)]
41. Espinosa-Gavira, M.J.; Agüera-Pérez, A.; Palomares-Salas, J.C.; de-la Rosa, J.J.G.; Sierra-Fernández, J.M.; Florencias-Olivero, O. Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method. *Sol. Energy* **2020**, *202*, 276–293. [[CrossRef](#)]
42. Hu, T.; Zheng, M.; Tan, J.; Zhu, L.; Miao, W. Intelligent photovoltaic monitoring based on solar irradiance big data and wireless sensor networks. *Ad Hoc Networks* **2015**, *35*, 127–136. [[CrossRef](#)]
43. Adelantado, F.; Vilajosana, X.; Tuset-Peiro, P.; Martinez, B.; Melia-Segui, J.; Watteyne, T. Understanding the Limits of LoRaWAN. *IEEE Commun. Mag.* **2017**, *55*, 34–40. [[CrossRef](#)]
44. Glória, A.; Dionisio, C.; Simões, G.; Cardoso, J.; Sebastião, P. Water Management for Sustainable Irrigation Systems Using Internet-of-Things. *Sensors* **2020**, *20*, 1402. [[CrossRef](#)]
45. García, L.; Parra, L.; Jimenez, J.M.; Parra, M.; Lloret, J.; Mauri, P.V.; Lorenz, P. Deployment Strategies of Soil Monitoring WSN for Precision Agriculture Irrigation Scheduling in Rural Areas. *Sensors* **2021**, *21*, 1693. [[CrossRef](#)]

CAPÍTULO 10

Documentación del doctorado

Plan de Investigación

Propuesta del plan de investigación del doctorando y aval del tutor y director(es) de tesis	
Programa de Doctorado	8215 Ingeniería Energética y Sostenible
Estudiante	NIF 15430855V - ESPINOSA GAVIRA, MANUEL JESÚS
Tutor	AGÜERA PEREZ, AGUSTIN
Codirectores	AGÜERA PEREZ, AGUSTIN GONZALEZ DE LA ROSA, JUAN JOSE
Fecha	29 de noviembre de 2018

De conformidad con lo establecido en el art.20 del **Reglamento UCA/ CG06/2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz**, mediante este documento D. MANUEL JESÚS ESPINOSA GAVIRA, con NIF 15430855V, propone el plan de investigación contenido en el archivo cuya referencia se especifica a continuación, con el aval su tutor y director(es) de tesis.

Referencia: PIN00152701
Nombre original del archivo: Plan_de_Investigacion._Espinosa_Gavira.Post- CA.v2_fdo_agu_jj.pdf
Peso del archivo: 1,08 Mb bytes
Fecha/ hora de carga: 29-11-2018 09:37:11
Ruta de acceso (requiere autentificación): https://posgrado.uca.es/cmF3Lh3ISwqAIBAA0BPIVBC1jYho5w2GIT_MiEpjnr-oLR8Ux9EKIEiJU7NSYZmGuQf9BRqL55-s6eKcFO5SOGUhPKjxTUpnqd22qjaiMxnJPxiCKsa9.pdf

El estudiante
D. MANUEL JESÚS ESPINOSA GAVIRA
Validado con fecha 29/11/18 09:39 h.

Aval del tutor
D. AGUSTIN AGÜERA PEREZ
Validado con fecha 29/11/18 09:46 h.

Aval del codirector
D. AGUSTIN AGÜERA PEREZ
Validado con fecha 29/11/18 09:46 h.

Aval del codirector
D. JUAN JOSE GONZALEZ DE LA ROSA
Validado con fecha 29/11/18 09:51 h.

**PLAN DE INVESTIGACIÓN DE TESIS DOCTORAL**
R.D. 99/2011**A. MEMORIA DEL PLAN DE INVESTIGACIÓN DE TESIS DOCTORAL***(A cumplimentar por el doctorando)*

Apellidos: ESPINOSA GAVIRA

Nombre: MANUEL JESÚS

D.N.I./Pasaporte: 15430855V Programa de doctorado: INGENIERÍA ENERGÉTICA Y SOSTENIBALE

Escuela de Doctorado: _____

Título de la tesis: REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

Director/es Dr. D. AGUSTÍN AGÜERA PÉREZ
Dr. D. JUAN JOSÉ GONZÁLEZ DE LA ROSA

1.- Resumen

Durante los últimos años, los sistemas de energéticos han evolucionado considerablemente, integrando energías renovables en los sistemas de generación, superando el 20% de la demanda en algunos países desarrollados. Esto es posible debido a la reducción de los costes que esta tecnología ha sufrido y la política de promover el uso de energías renovables. Por otra parte, empieza a notarse la evolución del uso de modelos enfocados al uso de sistemas de generación distribuidos, que además tienen un pilar fundamental en las microrredes – en inglés *microgrids* (MGs). Las energías renovables, y especialmente la energía solar, juegan un papel muy importante en este contexto.

Los sistemas de producción fotovoltaicos son dependientes principalmente de la radiación solar que reciben, siendo ésta un factor externo no controlable, lo que implica que su nivel de producción sea fluctuante. Estas perturbaciones en la generación están asociadas al paso de nubes sobre el sistema de generación y se caracterizan por tener una duración que va desde algunos segundos a varios minutos con un impacto sobre el índice de radiación también variable. Es importante tener en cuenta que, debido al funcionamiento del mercado eléctrico, y a las necesidades de operación de estos sistemas de producción, se hace indispensable disponer de modelos de predicción y sistemas de monitorización para diferentes horizontes espacio-temporales, y que es uno de los principales problemas a resolver, puesto que los sistemas de predicción de la radiación solar que existen actualmente son escasos y demasiado caros para ser contemplados por sistemas de producción de media y pequeña escala. Las predicciones a corto plazo se emplearían para el sistema de control y balance de la producción energética y a más largo plazo para la programación y la venta de energía en el mercado eléctrico. Las predicciones a largo plazo podrían estar cubiertas por modelos meteorológicos numéricos y/o basados en imágenes satélite. Para cubrir la necesidad de predicción a corto plazo se han realizado diversos estudios intentando estimar espacio-temporalmente el campo de irradiancia usando para ello métodos basados en imágenes satélite y en imágenes con cámaras de “cielo completo”, en inglés *all-sky cameras*. Varios de los investigadores más influyentes en predicción solar defienden que estos métodos no son efectivos debido a los problemas asociados de conversión de imágenes en irradiancia y traslado de esta a una distribución espacial precisa, **por ello** indican que las redes de sensores podrían jugar un papel esencial, ya que podrían ofrecer lo que se conoce como *ground-truth*, o niveles reales de irradiancia a modo de distribución espacial.

MEMORIA DEL PLAN DE INVESTIGACIÓN DE LA TESIS DOCTORAL

2

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

Recientes estudios han empleado redes de piranómetros distribuidas en grandes áreas para realizar una estimación del campo de irradiancia, pero no deja de ser una solución poco efectiva y cara para pequeños sistemas fotovoltaicos. Además, los piranómetros presentan ciertas carencias para eventos solares de muy corta duración, como es el caso del “cloud-enhacement”. Se trata de un evento un evento más rápido que el tiempo de respuesta típico de los piranómetros y que está siendo objeto de análisis y que consiste en un índice de radiación por encima del esperado debido a la concentración de radiación por el efecto de los bordes de la nube. Merece la pena destacar, que la mayoría de redes que se han empleado en estos estudios para predicciones a corto alcance temporal, son redes offline que registran datos de forma local en intervalos que van típicamente desde los 15 segundos hasta los 30 minutos. Estas características los descartan para aplicaciones de predicción, puesto que cuando los datos son recuperados, típicamente en semanas, el evento predicho deja de tener validez, además, esos tiempos de muestreo no le permitirían capturar eventos como el ya nombrado “cloud-enhacement”. Es aquí donde surge la necesidad de emplear sistemas de comunicaciones que permitan la transmisión de estos datos tan pronto como sea posible. En este aspecto se establecen como grandes candidatos las redes de sensores basadas en módulos de comunicación ZigBee, LoRa, LoRaWAN y WiFi. El concepto de unir las redes de sensores con necesidades de predicción de la radiación solar encaja en el concepto Internet of Energy, una variante dentro de Internet of Things, y es donde se centrará el plan de investigación, desarrollando una red de sensores inalámbrica de bajo coste, con capacidad de registrar eventos rápidos como el *cloud-enhacement*, que transmita los datos en tiempo real, para ello se estudiarán las diversas tecnologías anteriormente comentadas. Con los datos obtenidos de esta red se estudiarán diversos métodos de predicción para la estimación espacio-temporal del campo de irradiancia y estudiar las posibilidades de optimización de la producción del recurso solar en base a las estimaciones realizadas.

Con ello se pretende obtener un sistema de monitorización de la radiación solar de bajo coste para que pueda ser implementado desde pequeños sistemas de producción fotovoltaicos hasta sistemas de gran escala. Para ello se espera poder encontrar una tecnología inalámbrica que permita la creación de una red de sensores con una tasa de muestreo aceptable para las necesidades de monitorización de la variación de la radiación debido al paso de las nubes. Con los datos obtenidos de esta red de sensores se espera obtener estimaciones de evolución del campo de irradiancia después del estudio de diferentes algoritmos de predicción.

Por último, destacar que una red de sensores para radiación requiere de altas exigencias de muestreo y transmisión de datos, lo que permitiría adaptarse a otras necesidades, como redes de sensores de temperaturas y viento para el estudio de eficiencia energética en edificios, o el estudio de la advección de temperatura, conceptos englobados dentro de la temática conocida como Smart City o Urban Monitoring.

2.- Antecedentes y estado actual del tema

Es notable el crecimiento de producción de las energías renovables en el mix energético en los últimos años, sobre todo la energía solar y eólica. Estas energías precisan a día de hoy predicciones a diferentes escalas espacio-temporales, debido principalmente a la variación temporal de estos recursos, a la necesidad de planificación para un aprovechamiento óptimo de los recursos y al funcionamiento del mercado eléctrico [1], [2], [3] y [4]. En concreto Cross *et al.* remarcan en [1]:

"The high temporal variability of solar power is a real issue to achieve a balanced production and consumption. Solar power forecasting is then necessary to better exploit this variability and to increase the penetration of photovoltaic power into the energy mix. Solar energy forecasting involves prediction of cloud property above a given point [...]"

Los otros tres autores, [2], [3] y [4], además, clasifican el uso asociado a cada horizonte temporal de predicción, tal y como se muestra en las siguientes figuras y tablas:

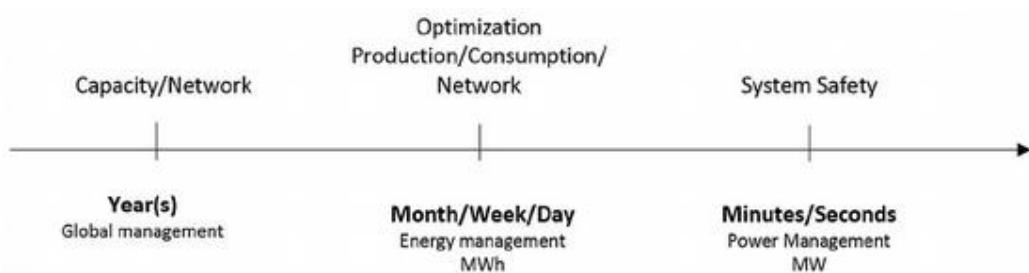


Figura 1. Escala de producción para la gestión energética en una red eléctrica. Figura de [2]

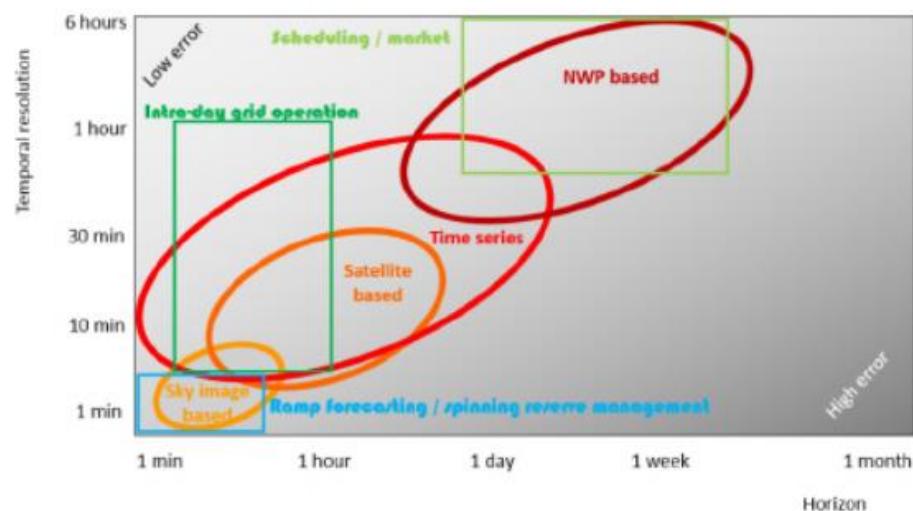


Figura 2. Errores de predicción vs modelos de predicción. Figura de [2]

MEMORIA DEL PLAN DE INVESTIGACIÓN DE LA TESIS DOCTORAL

4

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENSORES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

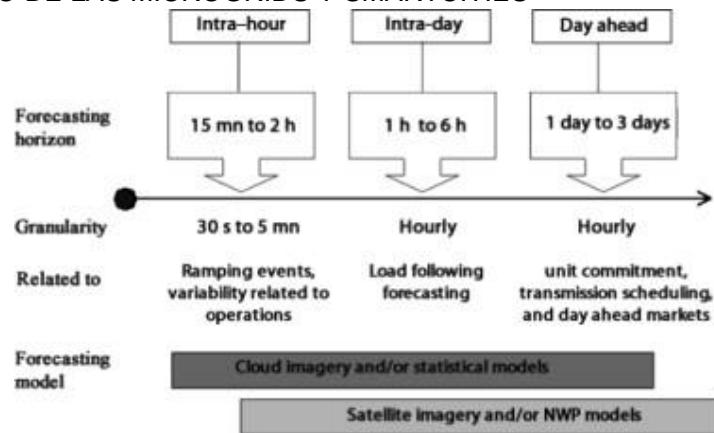


Figura 3. Relación entre horizontes, modelos y actividades. Figura de [3]

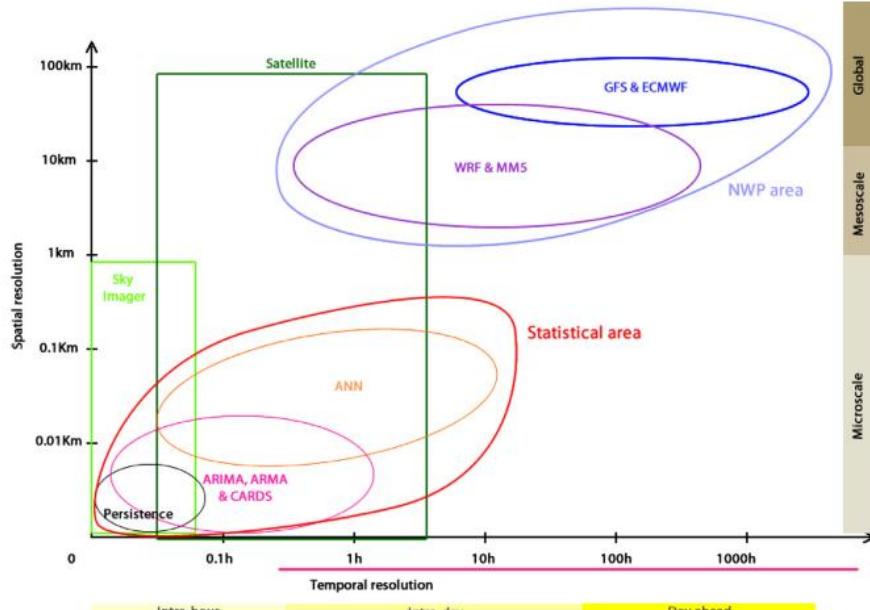


Figura 4. Clasificación de los modelos basados en las resoluciones espacio-temporales. Figura de [3]

Tabla 1. Horizontes temporales de la predicción. Tabla de [4].

Time horizon	Range	Possible purpose
Very Short-term /Nowcasting	A few seconds to 30 min	Electricity market clearing
Short-term	30–6 h	Economic load dispatching
Medium-term	6 h to 1 d	Operational security
Long-term	More than 1 d	Maintenance scheduling to optimize the operating cost

En el caso particular de la figura 2 y 4, se proponen los modelos de predicción a usar en función de la escala temporal, indicando métodos basados en imágenes de nubes y/o métodos estadísticos para los horizontes que abarcan desde unos segundos hasta unos 45 minutos. Por otra parte, matizan que desde

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENSORES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

los 30 minutos hasta varias horas son más aptos los métodos basados en imágenes satélite y/o modelos numéricos de predicción meteorológica.

Observando la propuesta de cada autor, rápidamente concluimos que el horizonte temporal que delimita la aplicación no está aun claramente definido, quedando únicamente de manifiesto, que hay unas necesidades de predicción en diferentes horizontes espacio-temporales.

La presente propuesta de plan de la investigación se enfoca a lo que se conoce como predicción de muy corto plazo temporal de la radiación solar – en inglés *very short-term forecast* o *nowcasting*. Estas variaciones de la radiación son principalmente debidas al paso de las nubes, por ello, varios investigadores han focalizado sus esfuerzos en caracterizarlas y determinar su movimiento. Algunos ejemplos de ello son [5], [6], [7] y [8] que utilizan imágenes de nubes capturadas desde la tierra, pero también hay autores que han estimado el movimiento de las nubes mediante imágenes obtenidas desde satélites como son los casos de [1], [9], [10] y [11] entre otros. Tantos artículos con fines similares sirven para hacer aún más patente la necesidad y el interés que suscita obtener una predicción del campo de irradiancia solar.

El estudio de la variación de la radiación debido al paso de las nubes podría traer un doble beneficio de forma inminente: optimización del sistema de control de producción y estudiar las posibilidades de explotación energéticas de la sobreirradiancia producida por el efecto de borde de nube, llamado en inglés *cloud-enhacement*. Este evento, como se indicaba en el resumen del presente plan, tiene una duración en el rango de los segundos, siendo lo suficientemente rápido para ser capturado por un piranómetro debido a su tiempo de respuesta. Además, esta sobreirradiancia puede superar la radiación solar extraterrestre, tal y como especifica Yordanov *et al.* [12], donde cito textualmente:

“The slow sensor registered an annual maximum of 1413 W/m², while the fast sensor’s range was found insufficient. A burst reaching 1528 W/m² was registered in June 2012. Near the Equator, bursts exceeding 1800 W/m² have been observed. These numbers are striking since the extraterrestrial solar irradiance peaks in January at about 1400 W/m². The phenomenon is attributed mainly to forward scattering of light in optically thin clouds (adjacent to the sun), which is much stronger for angles within 5° around the solar disk.”

Este párrafo es apoyado por la representación de datos tomadas de la siguiente figura:

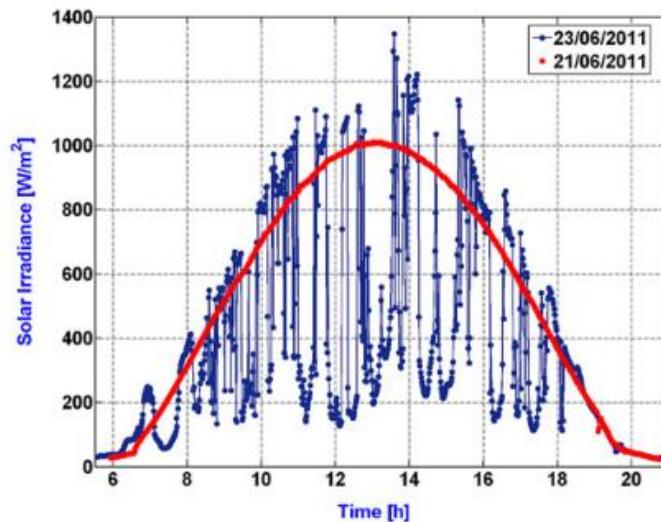


Figura 5. Comparación entre un día con cielo claro y otro con cielo parcialmente nublado. Figura de [12]

Este evento de sobreirradiancia suscita el interés de investigadores ya que se necesita capturar y caracterizar un evento recientemente descubierto y por ser el responsable de fallos, problemas y pérdidas de energía en los sistemas inversores de las plantas de generación fotovoltaica. Algunos casos son [13]

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

y [14] que presentan estudios de las pérdidas debido a este efecto y como se podría minimizar dichas pérdidas seleccionando inversores que tengan en cuenta tal efecto. A las variaciones de radiación solar se le atribuye el empeoramiento del índice de la calidad de la energía eléctrica tal y como queda evidenciado experimentalmente por Pakonen *et al.* en el artículo [15]. En él se tratan los efectos de parpadeos de tensión, en inglés *flickering*, por el efecto de las nubes sobre un sistema de generación conectado al sistema de distribución. Inzunza, por su parte Inzunza *et al.* en [16], centra la atención exclusivamente en el comportamiento del inversor cuando se le introduce una potencia superior por cortos períodos de tiempo, simulando el incremento de irradiancia debido a la reflexión en las nubes. Es evidente por tanto el interés en el estudio del movimiento de las nubes, la evolución del campo de irradiancia y sus efectos en los sistemas de generación para una integración y aprovechamiento óptimo del recurso solar.

Merece especial atención el trabajo de Yang *et al.* [17] ya que podría considerarse la revisión más extensa, actualizada y completa hecha hasta la fecha sobre predicción solar, con visos de convertirse en referencia básica para todos los futuros trabajos en el tema. En esta revisión se analizan más de 1000 artículos y se reseña cuáles son las tendencias en predicción solar. Concretamente, en el apartado 6.5.4. de esta revisión llamada *"Future trends in sensor network-based forecasting"*, los autores indican que las predicciones basadas en cámaras y satélites ocupan los dos extremos de la línea de representación del horizonte de predicción, siendo las nubes la principal fuente de variación de la radiación, pero matiza que las cámaras y los satélites han sido empleadas como las fuentes de datos más apropiadas a pesar de ciertas limitaciones. Con el creciente número de sistemas de sistemas de generación fotovoltaicos construidos, y que surgen necesidades de obtener la radiación real a nivel de suelo, las redes de sensores podrían jugar un papel de importancia en el futuro de la predicción solar, especialmente en el corto alcance temporal. Estos autores, además, puntualizan que el uso de redes de sensores con métodos de predicción como *kriging* se consideran que están en el estado del arte para la estimación espacio-temporal del campo de irradiancia, por lo que el uso de métodos de predicción combinado con redes de sensores, se posicionan como buenos candidatos para la estimación espacio-temporal de campo de irradiancia en el rango del corto alcance.

Algunos autores se han basado en este nuevo enfoque, pero apoyándose en redes existentes en lugar de realizar una red *ad hoc* para tal fin, entre los que cabe destacar a Lorenzo *et al.* con el artículo [18], que emplea 13 sensores irregularmente distribuidos por un área de 20 x 40 km, con un periodo de muestreo de 1 segundo y una latencia de 1 minuto. La red empleada presenta varios problemas a resolver, primero es la baja densidad de puntos de medición y la alta latencia. Algo similar le ocurre a Lohmann *et al.* en [19], que emplea una red externa más densa, pero también irregularmente distribuida. Otras redes empleadas es la presentada por Yang en el artículos [20] con un minuto de latencia y baja densidad de sensores. El principal problema que presentan estas redes, es que tanto su distribución espacial como su densidad de puntos de medición no pueden ofrecer un campo de irradiancia optimizado para las necesidades de un sistema de generación fotovoltaico, ya que la resolución espacial es baja y no se consigue disponer de los datos en tiempo real. Amaro e Silva *et al.* en [21] centra su atención en el estudio del impacto del diseño de la red y de la resolución espacio temporal en la predicción solar, realizando un gran trabajo en la síntesis de las redes de sensores más usadas y que detalla en la tabla 1 de su artículo, la cual se muestra a continuación:

Tabla 2. Resumen detallado de para los estudios previos más relevantes en la predicción solar espacio-temporal.

MODEL	DATA SOURCE	LOCATION	TIME RESOLUTION	AREA [KM ²]	FORECAST HORIZON	MAX SKILL [RESOLUTION; HORIZON]	REFERENCE
ADVECTIVE	PV	Nevada (USA)	1 s	1.8×0.5	1–150 min	16.2 [^] [1 s; 20 s]	Lipperheide et al. (2015)
LASSO	GS GHI	Hawaii (USA)	10 s	1×1	10 s–5 min	56 [^] [10 s; 10 s]	D. Yang et al. (2015)
KRIGING	GS GHI	Hawaii (USA)	10 s	1×1	10 s–5 min	43 [^] [50 s; 50 s]	Aryaputra et al. (2015)

MEMORIA DEL PLAN DE INVESTIGACIÓN DE LA TESIS DOCTORAL

7

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APPLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

ADVECTIVE	PV + GS GHI	Arizona (USA)	1 min	23 × 46	1 s–30 min	22.5 [^] [1 min; 5 min]	Lorenzo et al. (2015)
AR, ARX, ANN	GS GHI	California/Colorado (USA)	1 min, 1 h	196, 350	1–120 min	51.9* [1 h; 2 h]	C. Yang et al. (2015)
VARX, KRIGING, LASSO	GS GHI	Singapore	5 min	30 × 20	5 min	11.7* [5 min; 5 min]	Yang et al. (2014)
ADVECTIVE	PV + GS GHI	Arizona (USA)	5 min	37 × 44	5–30 min	17.9 [^] [5 min; 10 min]	Lorenzo et al. (2014)
CSTF	PV + GS GHI	Italy	10 min	113 × 77	10 min	24* [10 min; 10 min]	Tascikaraoglu et al. (2016)
ARX	GS GHI	Guadeloupe (Caribbean)	10 min, 1 h	ND	10 min/1 h	NC	Boland (2015)
ANALOG	PV	ND	10 min, 1 h	ND	10–30 min/1–3 h	10 [^] [10 min; 30 min]	Berdugo et al. (2011)
ANN	PV	Utrecht (NL)	15 min	10 × 10	15 min–1 month	35.5 [^] [15 min; 1 h]	Vaz et al. (2016)
ADVECTIVE	PV	Arizona (USA)	15 min	50 × 50	15–90 min	34.5 [^] [15 min; 30 min]	Lonij et al. (2013)
ANN	GS GHI	Castile and León (Spain)	15 min	9503	1–6 h	58.7 [^] [15 min; 3 h]	Gutierrez-Corea et al. (2016)
ARX	PV	South France	15 min	ND	15 min – 6 h	13.5* [15 min; 2 h]	Agoua et al. (2015)
ARX	Sat GHI	France	15 min	NA	15 min – 2 h	42 [^] [15 min; 1 h]	Dambreville et al. (2014)
ANN	Sat GHI	France	15 min	NA	15–60 min	31 ⁺ [15 min; 15 min]	Licciardi et al. (2015)
ARIMAX	PV + GS GHI	Singapore	15 min, 30 min	30 × 20	15/30 min	7.8 [^] [30 min; 30 min]	Nobre et al. (2016)
ANN	Sat GHI + GS GHI	California (USA)	30 min	NA	30 min – 2 h	25.3 [^] [30 min; 2 h]	Marquez et al. (2013)
ARX	PV current	Springbrook (AUS)	1 h, 24 h	0.25 × 0.4	1 h/24 h	25* [1 h; 1 h]	Basha et al. (2014)
ANN, K-NN, SVR	GS GHI	Italy	1 h	17 × 2	1 h	54.1* [1 h; 1 h]	Lazzaroni et al. (2015)
KRIGING	GS GHI	Singapore	1 h	30 × 20	1 h	30.8 [^] [1 h; 1 h]	Yang et al. (2013)
VARX	PV	Évora (Portugal)	1 h	40 × 45	1–6 h	27 ⁺ [1 h; 1 h]	Bessa et al. (2015)
ARX, ARX-GA, ANN, SVR	Sat GHI	California (USA)	1 h	NA	1–3 h	41.2 ⁺ [1 h; 3 h]	Zagouras et al. (2015)
ANN	Sat GHI	Gran Canaria (Spain)	1 h	NA	1–6 h	31.2 [^] [1 h; 6 h]	Mazorra Aguiar et al. (2015)
ANN	Sat GHI	France	3 h	NA	3 h	NC	Amrouche and Le Pivert (2014)

Esta tabla carece de información sobre si se trata de un sistema en offline o en tiempo real. Una tasa de transmisión de datos alta puede provocar problemas de estabilidad y latencia. Por lo general las redes rápidas suelen tener un alcance corto o requieren de una gran demanda de energía, por lo que la solución propuesta debería tener en cuenta estos aspectos. No obstante, el trabajo de Amaro e Silva es impecable, proveyendo una gran información para el resto investigadores que emplean sus esfuerzos en esta temática. De un rápido vistazo se observa que solo las 3 primeras redes podrían ser aptas para predicciones a muy corto plazo debido a su resolución temporal, aunque las áreas cubiertas sean relativamente grandes para sistemas fotovoltaicos de pequeña escala.

Yang *et al.* en [22] utiliza datos obtenidos de redes de piranómetros de California y Colorado. Implementa un nuevo método de predicción que se basa en aprovechar la combinación de las correlaciones en espacio y tiempo. La red propuesta por Aryaputra *et al.* en [23], que corresponde con la tercera entrada de la tabla de Amaro e Silva (Tabla 2), trata de una red aleatoriamente distribuida con una distancia mínima entre puntos de medición de 89m en la que no hace referencia a ninguna red de sensores ni sistemas de comunicación, por lo que se intuye que se trata de sensores con registradores de datos, para su posterior recogida y análisis.

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

No debemos olvidarnos que para la predicción de corto plazo es necesario el muestreo de datos por debajo del segundo, tal y como afirma Torregrossa *et al.* en [24]. Antonanzas *et al.* por su parte, en [25] remarca que el coeficiente de correlación de la predicción disminuye cuanto más lejos es el punto de predicción respecto a la zona de medición, como intuitivamente se podría llegar a pensar.

Cabe destacar que las redes de sensores basadas en piranómetros son soluciones caras para sistemas de producción fotovoltaicos de pequeña escala, cuyo coste podría no estar económicamente justificado, como se indica Gutierrez-Corea *et al.* en [26]: “[...] *the cost of the forecast service plus other automation infrastructure may not be economically justified.*”.

Según lo expuesto hasta ahora, las predicciones a corto plazo se deberían hacer con redes de sensores online, de bajo coste, con un tiempo de muestreo por debajo del segundo, con una alta densidad de puntos de medición cerca de la zona a predecir y con una baja latencia de transmisión de datos. En el artículo [27] realicé mi aportación en este tema, diseñando y realizando una red de sensores destinada a la monitorización de radiación y que cumpla los requisitos que demandan las necesidades actuales para la predicción de radiación en corto alcance espacio-temporal.

Es evidente por otra parte, que una red de sensores con requisitos tan exigentes como demanda la monitorización de la radiación para sistemas fotovoltaicos puede ser fácilmente adaptada a otras necesidades a cubrir. Por citar algunas posibilidades, la creciente preocupación por temas como la calidad del aire requiere de monitorización ambiental que pueden ser fácilmente resueltos con una red de sensores distribuidas por la ciudad, similar a la propuesta en [27]. Si se desarrollara una red de monitorización para la contaminación lumínica, podría servir además de apoyo a sistemas de predicción para las energías renovables que se encuentren cerca de los puntos de medición, creando una simbiosis entre la necesidad de los ciudadanos y de los sistemas de generación cercanos.

Cabe destacar que la información recogida por la red de sensores podría ser útil para sistemas de orden superior, como ejemplo se puede nombrar un sistema de predicción de radiación a nivel regional no requiere de tanto detalle de información como puede ser el obtenido por una red local de predicción espacio-temporal de corto alcance. En estos casos se puede hacer uso de una nueva técnica llamada *fog-computing*, de tal modo que se aprovechan los resultados de la computación de niveles inferiores para proveer datos a niveles superiores, ahorrando así, el coste de computación que llevaría el obtener el resultado de pequeña escala que no suele ser relevante para escalas mayores.

Por último, merece la pena reseñar la amplia experiencia del grupo de investigación en cuestiones tan específicas como comunicaciones, redes de sensores, sistemas de monitorización, análisis de datos ambientales, sistemas de predicción de diferentes tamaño y análisis de calidad del suministro eléctrico, por lo que se garantiza un alto soporte en estas cuestiones tan específicas. A continuación, se detalla cómo estas líneas pueden apoyar al plan de investigación:

- Línea de investigación sobre redes de sensores inalámbricas: El grupo cuenta con una amplia experiencia en análisis de diferentes tipos de redes según las necesidades. El grupo ha participado con esta temática en una conferencia internacional [28] y una conferencia nacional, [29], donde se trata las ventajas del uso del modo API sobre el modo AT y en revistas de divulgación científica no indexadas.
- Línea de investigación en monitorización solar: El grupo cuenta con aportando con un artículo en una revista JCR, posición 16/61 en 2017 (Q2) en ‘Instruments & Instrumentation’.
- Línea de investigación en predicción de viento a diferentes escalas, entre las que se puede destacar [30] y [31].
- Línea de investigación en calidad del suministro eléctrico: Esta línea puede ser de interés para el presente plan puesto que se optimizan los recursos necesarios para realizar el estudio del impacto de los efectos de la variación de la radiación solar sobre el índice de calidad del suministro eléctrico. El grupo presenta una amplia experiencia en esta línea, con diversas publicaciones: [32], [33], [34], [35], [36] y [37].

3.- Hipótesis y Objetivos

(Describir las razones por las que se considera pertinente plantear la investigación, la hipótesis de partida y los objetivos generales perseguidos en el transcurso de la investigación. Enumerar brevemente, con claridad, precisión y de manera realista (acorde con la duración de la tesis doctoral) los objetivos específicos.) (Máximo 12000 caracteres)

Como se ha descrito en el estado del arte anterior, la necesidad de redes de sensores que proporcionen información exacta, actualizada y con suficiente resolución espacio-temporal del campo de irradiancia local ha sido demandada en numerosos estudios de predicción solar como una línea importante para mejorar la gestión energética y la integración en la red de esta fuente de energía renovable. El plan de investigación está enfocado a analizar, plantear y, en la medida de lo posible, testear las distintas soluciones que se pueden adoptar para la implementación de redes de monitorización que provean información solar en el corto y muy corto plazo para la gestión óptima de los recursos fotovoltaicos a escala local; tomando siempre como referencia la micro-red como sistema energético más beneficiado de la disponibilidad de esta información y la Smart-city como entorno donde se proliferarán estos sistemas y que contará con una infraestructura de comunicaciones que permitirá el flujo de la información generada para un aprovechamiento a diferentes escalas espacio-temporales. Para ello se parte de la hipótesis de que los nuevos desarrollos en sistemas de comunicación y la disminución de los costes de los módulos de comunicación, permitirían cubrir las necesidades que se requiere actualmente la monitorización económica de la variación de la radiación solar fruto del paso de las nubes, y empleando estos datos como fuente para la aplicación de algoritmo de predicción para optimizar el recurso solar. Como objetivo principal se pretende definir las líneas básicas para el diseño, desarrollo e implantación de estos sistemas de monitorización, estableciendo las características apropiadas respecto a sensores, adquisición de datos y comunicaciones de manera que la información generada se adapte plenamente a las necesidades y capacidades de las microgrids e infraestructuras de la Smart-city.

El análisis espacio-temporal tendrá gran importancia en este estudio, dado que determinará la ubicación y densidad de los puntos de medición, así como las frecuencias de muestreo, cantidad de información generada y, consecuentemente, el flujo de datos de la red. Del mismo modo, esto determinará la selección y exactitud de los modelos usados para la estimación y predicción del campo de irradiancia. Para dicho análisis se pretende emplear una red online de sensores de iluminación para investigar la correlación entre el nivel de iluminación con la radiación solar tomada de un piranómetro como patrón de referencia. Esta correlación permitiría disminuir los costes de la red de monitorización de irradiancia significativamente. Se tiene en cuenta que esta correlación no sea la misma para cada punto de medición, y que además esté sujeta a variaciones en función de la estación del año, la densidad de las nubes y la altura de las mismas, estableciéndose así una correlación única y dinámica para cada sensor, que debería ir ajustándose automáticamente en función de los datos tomados por el piranómetro en períodos de estabilidad y que serán empleados como patrón de referencia.

De este modo se plantean los siguientes objetivos durante la ejecución del plan de investigación:

- Estudio y análisis de luxómetros y piranómetros como fuente de información para predicciones solares.
- Comparativa de tiempos de respuestas de diferentes fuentes de medición de radiación, como pueden ser piranómetros, luxómetros y paneles fotovoltaicos.
- Estudio y caracterización de sistemas de comunicaciones válidos para la predicción de irradiancia a corto plazo según el alcance del campo de irradiancia a estimar.
- Discusión del diseño óptimo de redes en tiempo real para predicción solar.
- Estudio de las posibilidades de redes de sensores matricialmente distribuida en el campo de la predicción solar.

MEMORIA DEL PLAN DE INVESTIGACIÓN DE LA TESIS DOCTORAL

10

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENSORES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

- Estudio del índice de cielo claro, en inglés *clear-sky index*, con datos obtenidos por una red de sensores en tiempo real.
- Estudio y comparación de diferentes técnicas de predicción con ~~conjuntos de datos adquiridos~~ los mapas de irradiancia obtenidos.
- Estudio de viabilidad de implementación de técnicas de estimaciones espacio-temporales en tiempo real con datos recibidos por una red de sensores.

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

4.- Metodología

(Detallar la metodología propuesta de acuerdo con los objetivos expuestos en el apartado 3) (Máximo 32000 caracteres)

El plan de investigación se pretende comenzar empleando diferentes sensores y equipos comerciales de medición lumínica, estos últimos empleados como verificadores de la correcta medición de los sensores. Esta sencilla prueba facilitará la selección de la mejor opción entre los candidatos pre-seleccionados acorde a sus características técnicas y verificar que su rango de medición es apropiado para la monitorización solar. Una vez seleccionado el sensor óptimo, se realizará un pre-diseño electrónico en el que se pueda verificar el correcto comportamiento del sensor frente a los luxómetros comerciales. Por otro lado, se realizará un circuito electrónico para el acondicionamiento de la señal débil proveniente del piranómetro. Este sistema deberá tener en cuenta que se trata de una señal muy débil, por lo que se debe tener en cuenta a la hora de amplificar esta señal evitando la amplificación y acople del ruido en la señal.

Con los pre-diseños del circuito del piranómetro y del sensor de luz, se realizará una monitorización de los valores de ambos dispositivos para determinar la posible correlación entre el nivel de iluminación y el nivel de radiación solar. Cabe destacar que ya existen que han intentado dicha correlación como es el caso de [38], que emplea una serie de sensores de iluminación pero abandona el estudio por no encontrar una buena correlación. Creemos que parte de esa mala correlación se debe a la diferencia de tiempos de respuesta entre el sensor de luz y el piranómetro, y parece ser que el autor no ha tenido en cuenta dicho factor. En una búsqueda más detenida, no se han encontrado más trabajos similares, donde se proponga redes de sensores que proponga sensores de iluminación como alternativa a las redes de sensores con piranómetros por lo que si se determina que es posible la correlación, los luxómetros se pueden convertir en grandes candidatos en el futuro de la predicción de los campos de irradiancia a bajo coste.

Es posible que la correlación encontrada no sea estática, y que varíe con diferentes factores como puede ser la estación del año, la hora del día, la altura y densidad de las nubes... entre otros factores a determinar. En este caso, se aplicarán correlaciones dinámicamente obtenidas mediante comparación con el piranómetro de calibración que deberá estar incluido en la red.

Debido a las necesidades inherentes de disponer de la información en tiempo real, se requiere de un sistema de comunicaciones que permita tal cometido, por lo que se realizará un estudio de las diferentes tecnologías y protocolos disponibles para pre-seleccionar los que mejor se adecuen a los requisitos del sistema. Entre estos sistemas de comunicaciones se posicionan como grandes candidatos las redes LoRa, LoRaWAN, WiFi y ZigBee. Se estudiará profundamente esta selección de comunicaciones, teniendo en cuenta las posibilidades de número de puntos de medición máximos admisibles, frecuencia de muestreo, latencia en la transmisión de datos, tasa de transferencia máxima y consumo energético de los módulos. Una vez seleccionado el sistema de comunicación, se verificará que la red en funcionamiento cumple con las necesidades específicas del sistema de monitorización, estudiándose, si fuese posible, las diferentes topologías que se pueden realizar con el sistema de comunicaciones seleccionado. Se realizarán numerosas pruebas a fin de conocer los límites de funcionamiento de la red de sensores.

Se procederá a realizar un diseño electrónico que incluya al menos el sistema de comunicaciones y el sensor seleccionado, así como la electrónica necesaria para su función, como pueden ser baterías, sistemas de gestión de carga y paneles solares que permitan la carga de las baterías para un funcionamiento ininterrumpido.

Se realizarán prototipos funcionales para la monitorización de la radiación, empleando como uno de los nodos de medición el piranómetro. Se verificará el comportamiento y se procederá a estudiar el procedimiento de correlación entre los datos de los sensores de luz y del piranómetro, para posteriormente implementar el algoritmo en el sistema online.

Como se comentaba en los antecedentes del presente plan, se requiere de los datos en tiempo real para poder realizar estimaciones espacio-temporales del campo de irradiancia, para ello, se deben soportar en los sistemas de comunicaciones estudiados.

Se realizarán tomas de datos de intervalos definidos en diferentes condiciones atmosféricas, a fin de caracterizar y obtener una correlación para una gran variedad de condiciones ambientales, de modo que permitan estudiar y verificar el correcto funcionamiento del sistema.

Se estudiará el comportamiento y las posibilidades de predicción en función de la configuración de la red de sensores, variándolas en tamaño y en frecuencia de muestreo. De este modo se pretende ofrecer unos valores de referencia que relacione las necesidades de frecuencia de muestreo con el área a cubrir junto con la cantidad de nodos a incluir en dicha área.

Se estudiarán diferentes distribuciones espaciales de los nodos para estudiar cuales de ellas presenta configuraciones más apropiadas para las estimaciones espacio-temporales, puesto que el relieve suele jugar un papel crucial en la distribución de las mismas, tal y como demuestran Yang *et al.* en [20]. A raíz de este estudio se evaluará la alternativa de distribución espacial más apropiada o la corrección mediante algoritmos similares a los usados por Yang *et al.*

Se analizarán en profundidad los métodos más empleados para estimaciones espacio-temporales, para determinar cuál de ellas se ajusta mejor, estudiándose la posibilidad de mejora realizando modificaciones sobre estos métodos.

Se obtendrán mapas de irradiancia en tiempo real, que serán actualizados según se vayan recibiendo nuevos datos de la red de sensores, esto permitirá determinar el correcto funcionamiento de la red en tiempo real y podría emplearse como primera herramienta de apoyo a los sistemas de generación fotovoltaicos, junto a estos mapas, se implementarán índices ampliamente usados en predicción solar, como pueden ser *clear-sky index* o *clearness index*.

Basándonos en los mapas de irradiancia anteriores, se implementará el algoritmo con mayor índice FS (*forecasting skill*) o más apropiado si el de mayor índice presenta alguna desventaja como exceso de necesidad de cómputo o complejidad del método.

Por último, cabe mencionar que la metodología planteada puede ser sujeta a modificaciones que susciten los avances en el plan de investigación o los avances en el campo de la predicción solar.

MEMORIA DEL PLAN DE INVESTIGACIÓN DE LA TESIS DOCTORAL

13

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APLICACIONES DE REDES DE SENSORES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

5.- Justificación de recursos disponibles

(Describir los **materiales, infraestructuras y equipamientos singulares** disponibles que permitirán abordar la metodología propuesta.)

Los objetivos son alcanzables con la mayor parte del equipamiento, materiales, capacidad económica e infraestructuras de las que dispone el grupo de investigación. Se cuenta con diversos sensores fotodiodos y fototransistores, que actuarán como luxómetros, además de varios luxómetros comerciales y un piranómetro CMP11 de Kipp&Zonen. Miembros del grupo de investigación tienen accesos a diversos recursos de datos de redes de monitorización que podrían ser usados como base de datos para diferentes estudios. Parte del material para la realización de pruebas con sistemas de comunicaciones, se encuentran disponibles a fecha de hoy, y otra gran parte se está en proceso de compra. Para la comparación de tiempo de respuestas, se cuentan con diversos paneles solares, que servirían como sistemas de alimentación para los nodos de las redes de sensores, así como para la comparativa de tiempos de respuestas. Para el análisis de datos obtenidos, se dispone de licencias de software para procesamiento de datos, MATLAB™ e instrumentación, LabView.

6.- Planificación temporal de trabajo

(Exponer la distribución temporal del trabajo, indicando el periodo de ejecución de cada uno de los objetivos propuestos)

Objetivo	Fecha estimada
Estudio y análisis de luxómetros y piranómetros como fuente de información para predicciones solares.	03/19
Estudio y caracterización de sistemas de comunicaciones válidos para la predicción de irradiancia a corto plazo según el alcance del campo de irradiancia a estimar.	
Discusión del diseño óptimo de redes en tiempo real para predicción solar.	09/19
Comparativa de tiempos de respuestas de diferentes fuentes de medición de radiación, como pueden ser piranómetros, luxómetros y paneles fotovoltaicos.	
Estudio de las posibilidades de redes de sensores matricialmente distribuida en el campo de la predicción solar. (Nótese que se requiere el diseño y puesta en funcionamiento de una red completa de monitorización según el área de monitorización prevista)	
Obtener mapas de irradiancias mediante datos adquiridos para su posterior estudio con técnicas de interpolación y predicción.	04/20
Estudio del índice de cielo claro, en inglés clear-sky index, con datos obtenidos por una red de sensores en tiempo real.	
Estudio y comparación de diferentes técnicas de predicción con conjuntos de datos adquiridos.	
Estudio de viabilidad de implementación de técnicas de estimaciones espacio-temporales en tiempo real con datos recibidos por una red de sensores.	10/20

7.- Implicaciones éticas y/o de bioseguridad de la investigación propuesta

n/a

8.- Bibliografía.

(Comentar brevemente la bibliografía más relevante.)

- [1] S. Cros, O. Liandrat, N. Sébastien, and N. Schmutz, "Extracting cloud motion vectors from satellite images for solar power forecasting," vol. pp. 4123-4126., 2014.

Este artículo se centra en la predicción solar basada en imágenes de satélite. Los autores describen como la alta variabilidad de la energía solar es un problema para alcanzar una producción balanceada con el consumo. Se remarca que la predicción de potencia solar es necesaria para que la energía solar penetre mejor en el mix energético. Este artículo también ilustra sobre la complejidad y problemas al hacer estimaciones de irradiancia basadas en este tipo de imágenes.

- [2] Cyril Voyant et al., "Machine learning methods for solar radiation forecasting: A review," *Renewable Energy*, pp. Pages 569-582, Volume 105, 2017.

- [3] Maimouna Diagne, Mathieu David, Philippe Lauret, John Boland, and Nicolas Schmutz, "Review of solar irradiance forecasting methods and a proposition for small-scale insular grids," vol. 27, pp. 65-76, 2013.

Se indica que la integración de la energía solar en la red eléctrica se está siendo esencial debido a su continuo crecimiento de uso, y que el uso eficiente de la salida fluctuante de energía de los paneles fotovoltaicos requiere de predicciones, y que la integración puede ofrecer mejor calidad del servicio si la irradiancia solar puede ser predicha con alta precisión.

- [4] Florian Barbieri, Sumedha Rajakaruna, and Arindam Ghosh, "Very short-term photovoltaic power forecasting with cloud modeling: A review," vol. Volume 75, Pages 242-263, no. <https://doi.org/10.1016/j.rser.2016.10.068>., 2017.

Los autores hacen hincapié en que la energía fotovoltaica no es totalmente predecible y por tanto es relativamente costoso y difícil hacer el despacho energético. En particular, sitúa las aplicaciones de redes de sensores aptas en el rango de resolución temporal que va desde algunos segundos hasta horas y las cámaras de cielo completo como dispositivos de aplicación en el rango de segundos a fracciones de segundo. Nótese que esta referencia puede cambiar significativamente con los avances en redes de sensores inalámbricas con altas tasas de transmisión de datos, tal y como apunta [17].

- [5] H., Xu, J., Peng, Z., Yoo, S., Yu, D., Huang, D., & Qin, H. Huang, "Cloud motion estimation for short term solar irradiation prediction," vol. pp. 696-701, no. doi: [10.1109/SmartGridComm.2013.6688040](https://doi.org/10.1109/SmartGridComm.2013.6688040), 2013.

- [6] Z. E. Jaouhari, Y. Zaz, and L. Masmoudi, "Cloud tracking from whole-sky ground-based images," vol. pp. 1-5, no. doi: [10.1109/IRSEC.2015.7455105](https://doi.org/10.1109/IRSEC.2015.7455105), 2015.

- [7] D. M. L. H. Dissawa, M. P. B. Ekanayake, G. M. R. I. Godaliyadda, and J. B. Ekanayake and A. P. Agalgaonkar, "Cloud motion tracking for short-term on-site cloud coverage prediction," vol. pp. 1-6, 2017.

- [8] Z. Zhen, F. Wang, Z. Mi, Y. Sun, and H. Sun, "Cloud tracking and forecasting method based on optimization model for PV power forecasting," vol. pp. 1-4, 2015.

- [9] R. Brad and I. A. Letia, "Extracting cloud motion from satellite image sequences," vol. pp. 1303-1307 vol.3., 2002.

Doctorando: ESPINOSA GAVIRA, MANUEL JESÚS

Título de la tesis: APPLICACIONES DE REDES DE SENsoRES PARA PREDICCIÓN SOLAR A CORTO PLAZO EN EL MARCO DE LAS MICROGRIDS Y SMARTCITIES

- [10] F. Eugenio and F. Marqués J. Marcello, "Cloud motion estimation in SEVIRI image sequences," vol. pp. III-642-III-645, 2009.

- [11] B. Goswami, "Temperature Induced Mean Based Cloud Motion Prediction Model for Multiple Cloud Clusters in Satellite Infrared Images," vol. pp. 279-282, 2014.

- [12] G. H. Yordanov, O. Midtgård, T. O. Saetre, and H. K. Nielsen and L. E. Norum, "Overirradiance (Cloud Enhancement) Events at High Latitudes," vol. vol. 3, no. 1, pp. 271-277, 2013.

Los autores analizan el eventos de sobreirradiancia, caracterizando eventos y dejando en evidencia que los sensores como los piranómetros son demasiado lentos como para capturar un evento de estas características y que los otros sensores que utilizaron con menor tiempo de respuesta no tienen el rango suficiente para capturar el evento sin saturarse.

- [13] Jan Kleissl, Keenan Murray Jennifer Luoma, "Optimal inverter sizing considering cloud enhancement," vol. Volume 86, Issue 1, Pages 421-429, no. <https://doi.org/10.1016/j.solener.2011.10.012.>, 2012.

Este artículo tiene especial relevancia debido a que enlaza el evento de sobreirradiancia debido a las nubes con la producción de un sistema fotovoltaico. En el artículo queda patente que la selección del inversor sin tener en cuenta el efecto de sobreirradiancia se traslada en pérdidas por la saturación de inversor en su capacidad de entregar potencia.

- [14] Jeremiah X. Johnson Jeremy Good, "Impact of inverter loading ratio on solar photovoltaic system performance," vol. Volume 177, Pages 475-486, no. <https://doi.org/10.1016/j.apenergy.2016.05.134.>, 2016.

- [15] A. Hilden, T. Suntio and P. Verho P. Pakonen, "Grid-connected PV power plant induced power quality problems — Experimental evidence," vol. pp. 1-10, 2016.

- [16] Ruben & Tawada, Yoshihiro & Furukawa, Motoko & Shibata, Naoya & Sumiya, Takeshi & Tanaka, Tsuguhiro & Kinoshita, Masahiro Inzunza, "Behavior of a photovoltaic inverter under sudden increase in irradiance due to reflection in clouds," vol. pp. 851-855., no. doi: 10.1109/ICRERA.2015.7418531, 2015.

- [17] Dazhi Yang, Jan Kleissl, Christian A. Gueymard, Hugo T.C. Pedro, and Carlos F.M. Coimbra, "History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining," vol. 168, pp. 60-101, no. <https://doi.org/10.1016/j.solener.2017.11.023.>, 2018.

Esta referencia puede considerarse la revisión más importante, actualizada y completa hasta la fecha sobre predicción solar. Se analizan más de 1000 artículos y las diversas técnicas existentes para obtener mapas de irradiancia, indicando el horizonte de aplicación válido de cada una de estas tecnologías. Se indica las principales limitaciones de algunas de las tecnologías y se proponen las posibles tecnologías adecuadas según el horizonte temporal de previsión. Con el creciente número de sistemas de sistemas de generación fotovoltaicos construidos, y que surgen necesidades de obtener la radiación real a nivel de suelo, las redes de sensores podrían jugar un papel de importancia en el futuro de la predicción solar, especialmente en el corto alcance temporal. Estos autores, además, puntualizan que el uso de redes de sensores con métodos de predicción como *kriging* se consideran que están en el estado del arte para la estimación espacio-temporal del campo de irradiancia, por lo que el uso de métodos de predicción combinado con redes de sensores, se posicionan como buenos candidatos para la estimación espacio-temporal de campo de irradiancia en el rango del corto alcance

- [18] Antonio T. Lorenzo, William F. Holmgren, and Alexander D. Cronin, "Irradiance forecasts based on an irradiance monitoring network, cloud motion, and spatial averaging," vol. 122, pp. 1158-1169, no. doi: 10.1016/j.solener.2015.10.038, 2015.

- [19] Gerald M. Lohmann, Adam H. Monahan, and Detlev Heinemann, "Local short-term variability in solar irradiance," vol. 16, no. 6365-6379, 2016.
- [20] Dazhi Yang, "On adding and removing sensors in a solar irradiance monitoring network for areal forecasting and PV system performance evaluation," vol. 155, pp. 1417-1430, no. <https://doi.org/10.1016/j.solener.2017.07.061>, 2017.
- [21] M. C. Brito, R. Amaro e Silva, "Impact of network layout and time resolution on spatio-temporal solar forecasting," vol. 163, pp. 329-337, no. <https://doi.org/10.1016/j.solener.2018.01.095>, 2018.
Los autores hacen un aporte a la comunidad científica, catalogando los principales modelos de predicción empleados y la fuente de datos empleada de diversos autores, así como las principales características, como la resolución temporal, área cubierta y horizonte de predicción.
- [22] C. Yang, A. A. Thatte, and L. Xie, "Multitime-Scale Data-Driven Spatio-Temporal Forecast of Photovoltaic Generation," vol. vol. 6, no. 1, pp. 104-112, 2015.
- [23] Aloysius W. Aryaputra, Lu Zhao Dazhi Yang, and Wilfred M. Walsh, "Very short-term irradiance forecasting at unobserved locations using spatio-temporal kriging," vol. 122, pp. 1266-1278, no. <https://doi.org/10.1016/j.solener.2015.10.023>, 2015.
- [24] D. Torregrossa, J.-Y. Le Boudec, and M. Paolone, "Model-free computation of ultra-short-term prediction intervals of solar irradiance," vol. 124, pp. 57-67, no. <https://doi.org/10.1016/j.solener.2015.11.017>, 2016.
- [25] N. Osorio, R. Escobar, R. Urraca, F.J. Martinez-de-Pison, F. Antonanzas-Torres J. Antonanzas, "Review of photovoltaic power forecasting," vol. 136, pp. 78-111, no. <https://doi.org/10.1016/j.solener.2016.06.069>, 2016.
- [26] Federico-Vladimir Gutierrez-Corea, Miguel-Angel Manso-Callejo, Maria-Pilar Moreno-Regidor, and Maria-Teresa Manrique-Sancho, "Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations," vol. 134, pp. 119-131, no. DOI: [10.1016/j.solener.2016.04.020](https://doi.org/10.1016/j.solener.2016.04.020), 2016.
- [27] Espinosa-Gavira MJ, Agüera-Pérez A, González de la Rosa JJ, Palomares-Salas JC, and Sierra-Fernández JM., "An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems," *Sensors, MDPI*, vol. 18(18):3405, no. DOI: [10.3390/s18103405](https://doi.org/10.3390/s18103405), 2018.
- [28] A Jimenez-Pro, JJ Gonzalez-de-la-Rosa, A Aguera-Perez, O Florencias-Oliveros, JC Palomares-Salas, JM Sierra-Fernandez MJ Espinosa-Gavira, "Improving Flexibility in Wireless Sensor Networks via API. An Application in Environmental Monitoring , Paris, 2018, pp. 1-4.," *9th IFIP International Conference on New Technologies, Mobility and Security (NTMS)*, no. doi: [10.1109/NTMS.2018.8328697](https://doi.org/10.1109/NTMS.2018.8328697), pp. pp. 1-4, 2018.
- [29] M.J. Espinosa-Gavira, A. Jiménez-Pro, and J.J. González-de-la-Rosa, "Mejora de la flexibilidad de redes de sensores inalámbricas mediante el uso del modo API. Una aplicación en monitorización ambiental," *Seminario Anual de Automática, Electrónica Industrial e Instrumentación*, no. ISBN: 978-84-947311-4-3, pp. 227-230, 2018.
- [30] Agustín Agüera-Pérez, José Carlos Palomares-Salas, Juan José González de la Rosa, and José María Sierra-Fernández, "Regional wind monitoring system based on multiple sensor networks: A crowdsourcing preliminary test," *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 127, no. ISSN 0167-6105. <https://doi.org/10.1016/j.jweia.2014.02.006>, pp. 51-58, 2014.
- [31] Agustín Agüera-Pérez, José Palomares-Salas, and Antonio Moreno-Munoz, "Spatial persistence in wind analysis," *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 119, 48–52, no. doi: [10.1016/j.jweia.2013.05.011](https://doi.org/10.1016/j.jweia.2013.05.011), 2013.

- [32] Olivia Florencias-Oliveros, J. J. de la Rosa, Agustín Agüera-Pérez, and José. Palomares-Salas, "Discussion on Reliability and Power Quality in the Smart Grid: a prosumer approach of a time scalable index," *Renewable Energy and Power Quality Journal*, vol. 1. 108-113, no. doi: 10.24084/repqj16.228., 2018.
- [33] J.-J. González-de-la-Rosa, A. Agüera-Pérez, J.-C. Palomares-Salas, O. Florencias-Oliveros, and J.-M. Sierra-Fernández, "A Dual Monitoring Technique to Detect Power Quality Transients Based on the Fourth-Order Spectrogram," *Energies*, vol. 11. 503, no. doi: 10.3390/en11030503., 2018.
- [34] José Sierra-Fernández, J. J. de la Rosa, Agustín Agüera-Pérez, José Palomares-Salas, and Olivia Florencias-Oliveros, "Evaluation of a new Power Quality index, based in Higher Order Statistics," *Renewable Energy and Power Quality Journal*, vol. 1. 37-42, no. doi: 10.24084/repqj15.210, 2018.
- [35] José & de la Rosa, J. J. & Sierra-Fernández, José & Agüera-Pérez, Agustín Palomares-Salas, "HOS network-based classification of power quality events via regression algorithms. Series: Advanced signal processing techniques and telecommunications network infrastructures for Smart Grid analysis, monitoring and management," *EURASIP J. Adv. Signal Process.*, vol. 49. 1-11, no. DOI 10.1186/s13634-015-0204-3, 2015.
- [36] M. J. Espinosa-Gavira, Juan-José González de la Rosa, A. Agüera-Pérez, José Carlos Palomares-Salas, J. M. Sierra-Fernández Olivia Florencias-Oliveros, "Real-life Power Quality Sags," *IEEE Dataport*, no. <http://dx.doi.org/10.21227/H2K88D>, 2017.
- [37] Olivia Florencias-Oliveros et al., "Real-life Power Quality Transients," *IEEE Dataport*, no. <http://dx.doi.org/10.21227/H2Q30W>, 2017.
- [38] H. Schenk et al., "Design and Operation of an Irradiance Measurement Network," vol. 69, pp. 2019-2030, no. <https://doi.org/10.1016/j.egypro.2015.03.212>, 2015.
Esta cita hace referencia al que es posiblemente el estudio más grande de redes de monitorización de irradiancia, desarrollándose en las instalaciones de la plataforma solar de Almería. Este estudio contempla diferentes sensores para la red de monitorización de irradiancia, entre ellos un medidor de iluminancia "MSR 145" que emplea un sensor SFH5712, que difiere del propuesto, SFH 5711, del tipo de salida, siendo el primero por comunicación I2C y el segundo por salida en corriente proporcional a la medida. Señalan que la solución más efectiva a nivel económico se basa en emplear estos medidores de iluminancia en lugar de piranómetros, pero han sido descartados en el desarrollo por encontrar variaciones en la calidad de la medida entre diferentes instrumentos.
- [39] M. Lipperheide, "Embedded nowcasting method using cloud speed persistence for a photovoltaic power plant," vol. 112, pp. 232-238, no. <https://doi.org/10.1016/j.solener.2014.11.013>., 2015.

Documento de actividades del doctorando

Actividad formativa: 8215B01 Presentación de resultados de la investigación en el Grupo/ Equipo de Investigación

Tipo: Obligatoria (mínimo 10.00 h.)		Horas realizadas: 40.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2020/21	Avance y optimización de redes de sensores	jornada_2_presentacion_TIC_168.20191122..pdf	10.00	
2020/21	Demostración de funcionamiento en tiempo real de la red de sensores	jornada_3_presentacion_TIC_168.20191122..pdf	10.00	
2020/21	Desarrollo de redes de sensores para medida de radicación solar	jornada_1_presentacion_TIC_168.pdf	10.00	
2020/21	Implementación de algoritmos habituales para estimación del	jornada_4_presentacion_TIC_168.20191122..pdf	10.00	

Actividad formativa: 8215B02 Publicación en Revista Indexada ISI- JCR

Tipo: Obligatoria (mínimo 200.00 h.)		Horas realizadas: 300.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	AN ON- LINE LOW- COST IRRADIANCE MONITORING NETWORK WITH SUB	sensors-18-03405.pdf	275.00	
2018/19	Se solicita revalidación por tener indice Q1 en 2018	sensors-18-03405.20190621131307.pdf	25.00	

Actividad formativa: 8215B03 Presentación de un plan de investigación

Tipo: Obligatoria (mínimo 50.00 h.)		Horas realizadas: 50.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	Certificado presentación plan de investigación en JORPDIEES	Presentacion_plan_de_investigacion_8215..pdf	50.00	

Actividad formativa: 8215B04 Metodología de la Investigación aplicada a la Ingeniería Energética y Sostenible

Tipo: Obligatoria (mínimo 35.00 h.)		Horas realizadas: 35.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	Realizado en el curso académico 17/18	15430855V_MetodologA_a_de_la_investigac...pdf	35.00	

Actividad formativa: 8215P01 Presentación de resultados de la investigación en el ámbito de la UCA: Jornadas Pre- doctorales en Ingeniería

Tipo: Optativa		Horas realizadas: 50.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	Presentacion en JORPDIES	Jornadas_PDIES_presentacion_resultados.pdf	50.00	

Actividad formativa: 8215P02 Publicación en revista no indexada en ISI- JCR

Tipo: Optativa		Horas realizadas: 100.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2017/18	Revista Automática e Instrumentacion numero 497	aei497_57-64_TECHOLOGIA_smart_grids.pdf	100.00	

Actividad formativa: 8215P03 Participación en proyectos y contratos I +D +I

Tipo: Optativa		Horas realizadas: 200.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	TEC2016-77632- C3-3- R: CONTROL Y GESTION DE NANORREDES AISLABLES	Certificado_equipo_trabajo_COMINGSISEM....pdf	200.00	

Actividad formativa: 8215P06 Presentación y tramitación de una patente

Tipo: Optativa		Horas realizadas: 200.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2018/19	Procedimiento y sistema de análisis de calidad de la energía e í	Solicitud_Patente_- _P201700746- Instanci...pdf	200.00	

Actividad formativa: 8215P10 Ponencia en Congreso Internacional

Tipo: Optativa		Horas realizadas: 100.00 h.	Actividad superada	
Curso	Descripción		Documento justificativo	Horas
2017/18	E Proceedings Conferencia Internacional NTMS - París 2018	NTMS2018- E- PROCEEDING.pdf	100.00	

Actividad formativa: 8215P11 Presentación de resultados de la investigación en un Congreso Nacional

Tipo: Optativa	Horas realizadas: 50.00 h.	Actividad superada
Curso	Descripción	Documento justificativo
2018/19	PRESENTACIÓN DE RESULTADOS EN SAAEI 18	ESPINOSA_GAVIRA.SAAEII_2018_XXV_Libro_d...pdf
		50.00

Actividad formativa: 8215P15 Asistencia a conferencias

Tipo: Optativa	Horas realizadas: 7.00 h.	Actividad superada
Curso	Descripción	Documento justificativo
2017/18		certificado_asistencia_algeciras_8.2018...pdf
2018/19	ornadas Doctorales transversales UCA (EDUCA)	15430855V_EDUCA.pdf
		5.00

Actividad formativa: 8215T01 Iniciación a los estudios de Doctorado

Tipo: Transversal (mínimo 25.00 h.)	Horas realizadas: 25.00 h.	Actividad superada
Curso	Descripción	Documento justificativo
2018/19		Curso_iniciacion_doctorado.pdf
		25.00

Actividad formativa: 8215T02 Búsqueda, gestión, comunicación y difusión de la información científica

Tipo: Transversal (mínimo 30.00 h.)	Horas realizadas: 30.00 h.	Actividad superada
Curso	Descripción	Documento justificativo
2018/19		Busqueda_gestion_y_comunicaciA_n_de_la_...pdf
		30.00

Total horas actividades formativas completadas:**1187.00**

Las horas especificadas corresponden a las reconocidas por la Comisión Académica del Programa en el día de la fecha.
El estudiante ha completado todos los requisitos de su plan de estudios para la superación de las actividades formativas.

Cádiz, a 30 de septiembre de 2022

10.1 Informe con el factor de impacto y cuartil de Journal Citation Reports (SCI o SSCI)

Artículo 1 (Apéndice I)

Título: An on-line low-cost irradiance monitoring network with sub-second sampling adapted to small-scale PV system

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, Juan José González de la Rosa, José Carlos Palomares-Salas y José María Sierra-Fernández

Revista, año y EISSN: Sensors (2018) 1424-8220

DOI: <https://doi.org/10.3390/s18103405>

Factor de impacto JCR 2018: 3.031

Posición de la revista según área JCR en 2018:

- **Instruments & Instrumentation:** 15/61 (Q1)
- **Electrochemistry:** 12/26 (Q2)
- **Cheministry, analytical:** 23/84 (Q2)

Abstract

Very short-term solar forecasts are gaining interest for their application on real-time control of photovoltaic systems. These forecasts are intimately related to the cloud motion that produce variations of the irradiance field on scales of seconds and meters, thus particularly impacting in small photovoltaic systems. Very short-term forecast models must be supported by updated information of the local irradiance field, and solar sensor networks are positioning as the more direct way to obtain these data. The development of solar sensor networks adapted to small-scale systems as microgrids is subject to specific requirements: high updating frequency, high density of measurement points and low investment. This paper proposes a wireless sensor network able to provide snapshots of the irradiance field with an updating frequency of 2 Hz. The network comprised 16 motes regularly distributed over an area of 15 m × 15 m (4 motes × 4 motes, minimum intersensor distance of 5 m). The irradiance values were estimated from illuminance measurements acquired by lux-meters in the network motes. The estimated irradiances were validated with measurements of a secondary standard pyranometer obtaining a mean absolute error of 24.4 W/m² and a standard deviation of 36.1 W/m². The network was able to capture the cloud motion and the main features of the irradiance field even with the reduced dimensions of the monitoring area. These results and the low-cost of the measurement devices indicate that this concept of solar sensor networks would be appropriate not only for photovoltaic plants in the range of MW, but also for smaller systems such as the ones installed in microgrids.

Artículo 2 (Apéndice II)

Título: Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José-Carlos Palomares-Salas, Juan-José González-de-la-Rosa, José-María Sierra-Fernández, Olivia Florencias-Oliveros

Revista, año y EISSN: Solar Energy (2020) 1471-1257

DOI: <https://doi.org/10.1016/j.solener.2020.03.081>

Factor de impacto JCR 2020: 5.742

Posición de la revista según área JCR en 2020:

- **Energy & Fuels:** 38/114 (Q2)

Abstract

Small-scale PV generation is particularly affected by the irradiance variability produced by cloud shadows. Accurate predictions of the clouds passing over the PV field are thus necessary for the optimized management and integration of this renewable power source. Two main elements are required to perform these predictions: the local irradiance field and the cloud motion vector. Irradiance sensor networks are positioning as a promising data source at the spatial and temporal scales of the problem, avoiding the irradiance inference problems and costs of image-based instrumentation. This paper proposes a method to infer the cloud shadow motion vector from small-scale irradiance sensor networks data. The method does not require specific network configuration or layout, and the algorithm is computationally simple: graphical solutions are obtained by aggregating mean absolute errors in a diagram/matrix with each element representing a possible displacement of the cloud shadows. The validation is conducted with a fractal cloud model that allows the generation of irradiance time series according to an arbitrary cloud motion vector. The most correlated pair and the linear cloud edge methods are used for benchmarking purposes. Gridded and non-gridded sensors layouts are tested with number of sensors ranging from 9 to 100, monitored areas from 100 to 10000 m², and sampling periods from 0.3 to 3.3 s. The results show the superiority of the proposed method with a reduction of 50–90 % of the root mean square errors respect to the benchmark methods in 75 % of the tests. Additionally, the proposed method maintains similar performance as sampling rate decreases, while the benchmark methods exhibit worsening results.

Artículo 3 (Apéndice III)

Título: Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

Autores: Manuel Jesús Espinosa-Gavira, Agustín Agüera-Pérez, José María Sierra-Fernández, Juan José González de-la-Rosa, José Carlos Palomares-Salas y Olivia Florencias-Oliveros

Revista, año y EISSN: Sensors (2022) 1424-8220

DOI: <https://doi.org/10.3390/s22082928>

Factor de impacto JCR 2021: 3.847

Posición de la revista según área JCR en 2021:

- **Instruments & Instrumentation:** 19/64 (Q2)
- **Cheministry, analytical:** 29/87 (Q2)
- **Engineering, Electrical & Electronic:** 95/276 (Q2)

Abstract

Cloud-induced photovoltaic variability can affect grid stability and power quality, especially in electricity systems with high penetration levels. The availability of irradiance field forecasts in the scale of seconds and meters is fundamental for an adequate control of photovoltaic systems in order to minimize their impact on distribution networks. Irradiance sensor networks have proved to be efficient tools for supporting these forecasts, but the costs of monitoring systems with the required specifications are economically justified only for large plants and research purposes. This study deals with the design and test of a wireless irradiance sensor network as an adaptable operational solution for photovoltaic systems capable of meeting the measurement specifications necessary for capturing the clouds passage. The network was based on WiFi, comprised 16 pyranometers, and proved to be stable at sampling periods up to 25 ms, providing detailed spatial representations of the irradiance field and its evolution. As a result, the developed network was capable of achieving comparable specifications to research wired irradiance monitoring network with the advantages in costs and flexibility of the wireless technology, thus constituting a valuable tool for supporting nowcasting systems for photovoltaic management and control.

Conformidad y renuncia de los coautores

Tesis por compendio de publicaciones
Documento de conformidad y renuncia de coautores

D./Dª.: Agustín Agüera Pérez con DNI: 44043728Q coautor de la publicación que se identifica a continuación:

- An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems
- Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method
- Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

de acuerdo con lo establecido en el **Artículo 23.4 del Reglamento UCA/CG06/2012, de 27 de junio de 2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz (BUOCA nº 208)**.

Manifiesta su conformidad para la presentación de la citada publicación como parte de la tesis doctoral de D./Dª. Manuel Jesús Espinosa Gavira, titulada Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities

Y expresa su renuncia a presentar la citada publicación como parte de otra tesis doctoral en cualquier otra universidad.

En Algeciras, a fecha de firma

AGUERA
PEREZ
AGUSTIN -
44043728Q
Fdo.: _____

Firmado digitalmente por AGUERA
PEREZ AGUSTIN - 44043728Q
Nombre de reconocimiento (DN):
c=ES,
serialNumber=IDCES-44043728Q,
givenName=AGUSTIN, sn=AGUERA
PEREZ, cn=AGUERA PEREZ AGUSTIN
- 44043728Q
Fecha: 2022.10.03 13:30:56 +02'00'

Tesis por compendio de publicaciones
Documento de conformidad y renuncia de coautores

D./Dª.: Juan José González de la Rosa con DNI: 31854832Q coautor de la publicación que se identifica a continuación:

- An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems
- Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method
- Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

de acuerdo con lo establecido en el **Artículo 23.4 del Reglamento UCA/CG06/2012, de 27 de junio de 2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz (BUOCA nº 208)**.

Manifiesta su conformidad para la presentación de la citada publicación como parte de la tesis doctoral de D./Dª. Manuel Jesús Espinosa Gavira, titulada Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities

Y expresa su renuncia a presentar la citada publicación como parte de otra tesis doctoral en cualquier otra universidad.

En Algeciras, a fecha de firma

GONZALEZ
DE LA ROSA
JUAN JOSE -
31854832Q
Fdo.: _____

Firmado
digitalmente por
GONZALEZ DE LA
ROSA JUAN JOSE -
31854832Q
Fecha: 2022.10.01
13:01:43 +02'00'

Tesis por compendio de publicaciones
Documento de conformidad y renuncia de coautores

D./Dª.: José Carlos Palomares Salas con DNI: 31867371C coautor de la publicación que se identifica a continuación:

- An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems
- Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method
- Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

de acuerdo con lo establecido en el **Artículo 23.4 del Reglamento UCA/CG06/2012, de 27 de junio de 2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz (BUOCA nº 208).**

Manifiesta su conformidad para la presentación de la citada publicación como parte de la tesis doctoral de D./Dª. Manuel Jesús Espinosa Gavira, titulada Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities

Y expresa su renuncia a presentar la citada publicación como parte de otra tesis doctoral en cualquier otra universidad.

En Algeciras, a fecha de firma

PALOMARES
SALAS JOSE
CARLOS - DNI
31867371C

Firmado digitalmente por PALOMARES SALAS
JOSE CARLOS - DNI 31867371C
Nombre de reconocimiento (DN): c=ES,
o=UNIVERSIDAD DE CADIZ, ou=CERTIFICADO
ELECTRONICO DE EMPLEADO PUBLICO,
ou=DEPARTAMENTO ING AUTOMATICA
ELECTRONICA
serialNumber=d1CF5-31867371C
sn=PALOMARES SALAS, givenName=JOSE
CARLOS, cn=PALOMARES SALAS JOSE
CARLOS - DNI 31867371C
Fecha: 2022.10.01 11:34:39 +02'00'

Fdo.: _____

Tesis por compendio de publicaciones
Documento de conformidad y renuncia de coautores

D./Dª.: Jose María Sierra Fernández con DNI: 75905786J coautor de la publicación que se identifica a continuación:

- An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems
- Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method
- Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

de acuerdo con lo establecido en el **Artículo 23.4 del Reglamento UCA/CG06/2012, de 27 de junio de 2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz (BUOCA nº 208)**.

Manifiesta su conformidad para la presentación de la citada publicación como parte de la tesis doctoral de D./Dª. Manuel Jesús Espinosa Gavira, titulada Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities

Y expresa su renuncia a presentar la citada publicación como parte de otra tesis doctoral en cualquier otra universidad.

En Algeciras, a fecha de firma

SIERRA
FERNANDEZ
JOSE Mª -
75905786J

Firmado digitalmente
por SIERRA
FERNANDEZ JOSE Mª -
75905786J
Fecha: 2022.10.08
13:17:54 +02'00'

Fdo.: _____

Tesis por compendio de publicaciones
Documento de conformidad y renuncia de coautores

D./Dª.: Olivia Florencias Oliveros con DNI: 78420243H coautor de la publicación que se identifica a continuación:

- An On-Line Low-Cost Irradiance Monitoring Network with Sub-Second Sampling Adapted to Small-Scale PV Systems
- Cloud motion estimation from small-scale irradiance sensor networks: General analysis and proposal of a new method
- Design and Test of a High-Performance Wireless Sensor Network for Irradiance Monitoring

de acuerdo con lo establecido en el **Artículo 23.4 del Reglamento UCA/CG06/2012, de 27 de junio de 2012, por el que se regula la ordenación de los estudios de doctorado en la Universidad de Cádiz (BUOCA nº 208)**.

Manifiesta su conformidad para la presentación de la citada publicación como parte de la tesis doctoral de D./Dª. Manuel Jesús Espinosa Gavira, titulada Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities

Y expresa su renuncia a presentar la citada publicación como parte de otra tesis doctoral en cualquier otra universidad.

En Algeciras, a fecha de firma

Fdo.: _____

FLORENCIA S OLIVEROS OLIVIA -
78420243H

Firmado digitalmente por
FLORENCIAS OLIVEROS OLIVIA -
78420243H
Nombre de reconocimiento (DN):
c=ES,
serialNumber=IDCES-78420243H,
givenName=OLIVIA,
sn=FLORENCIAS OLIVEROS,
cn=FLORENCIAS OLIVEROS OLIVIA
- 78420243H
Fecha: 2022.11.04 18:09:12 +01'00'

Informe favorable del director de tesis

ANEXO II
MODELO DE INFORME FAVORABLE DEL DIRECTOR(ES) DE LA TESIS
PARA EL DEPÓSITO DE TESIS DOCTORALES DESARROLLADAS DE
ACUERDO CON EL REAL DECRETO 99/2011, DE 28 DE ENERO

D./D^a. **Agustín Agüera Pérez**, y D/D^a. **Juan José González de la Rosa**, director (es) de la tesis doctoral de D./D^a. **Manuel Jesús Espinosa Gavira**, alumno/a del programa de doctorado **Ingeniería Energética y Sostenible**, regulado por el Real Decreto 99/2011, de 28 de enero, por el que se regulan las enseñanzas oficiales de doctorado, informa(n) favorablemente la solicitud de autorización para el depósito de la tesis doctoral de D./D^a. **Manuel Jesús Espinosa Gavira**, titulada **Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities**, y desarrollada de acuerdo con los requisitos de control de calidad para las tesis doctorales recogidos en la memoria del programa de doctorado de referencia.

En Algeciras, a 3 de octubre de 2022

Fdo.: AGUERA
PEREZ
AGUSTIN -
44043728Q

Firmado digitalmente por
AGUERA PEREZ AGUSTIN -
44043728Q
Número de reconocimiento
(DN)
SerialNumber=IDCES-4404372
8Q, givenName=AGUSTIN,
sn=AGUERA PEREZ,
cn=AGUERA PEREZ AGUSTIN -
44043728Q
Fecha: 2022.10.03 14:07:21
+02'00'

Fdo.: GONZALEZ
DE LA ROSA
JUAN JOSE -
31854832Q

Firmado
digitalmente por
GONZALEZ DE LA
ROSA JUAN JOSE -
JUAN JOSE - 31854832Q
31854832Q Fecha: 2022.10.13
15:50:40 +02'00'

NOTA

El Informe deberá venir acompañado de un pronunciamiento expreso del director (o directores) de la investigación acerca de la adecuación del resultado de la investigación (la tesis) al proyecto presentado en su momento, el correcto desarrollo del proceso de formación doctoral del doctorando y la validez y la oportunidad de los resultados de la investigación plasmados en la tesis.

**Sr. Presidente de la Comisión Académica del Programa de Doctorado Ingeniería
Energética y Sostenible**

**Solicitud de autorización para el
depósito de Tesis Doctoral**

ANEXO I
SOLICITUD DE AUTORIZACIÓN PARA EL DEPÓSITO DE LA TESIS
DOCTORAL (REAL DECRETO 99/2011, DE 28 DE ENERO)

D./D^a. **Manuel Jesús Espinosa Gavira**, investigador en formación del programa de doctorado **Ingeniería Energética y Sostenible**, regulado por el Real Decreto 99/2011, de 28 de enero, *por el que se regulan las enseñanzas oficiales de doctorado*, una vez completada su formación doctoral y habiendo superado la evaluación definitiva de su plan de investigación, solicita a la Comisión Académica del programa de doctorado arriba citado autorización para proceder al depósito, en la Secretaría General de esta Universidad, de la tesis doctoral titulada **Redes de sensores para la predicción solar a corto plazo en el marco de las microgrids y smartcities**, dirigida por el/los Drs. D./D^a. **Agustín Agüera Pérez** y D./D^a **Juan José González de la Rosa**

En Cádiz, a 3 de octubre de 2022

ESPINOSA
GAVIRA MANUEL
JESUS -
Fdo.: 15430855V

Firmado digitalmente por
ESPINOSA GAVIRA
MANUEL JESUS -
15430855V
Fecha: 2022.10.03
14:14:20 +02'00'

IMPORTANTE

La presente solicitud deberá acompañarse del Informe favorable del director (es) de la tesis, así como de un ejemplar de la tesis doctoral y de una copia del Documento de Actividades del doctorando.

Informe administrativo de la Oficina de Posgrado

Revisado el expediente de doctorado de D./D^a._____, la Oficina de Posgrado, considerando el cumplimiento necesario de los requisitos administrativos establecidos, informa que el interesado se encuentra en disposición de hacer el depósito de su tesis doctoral en la Secretaría General de la Universidad.

(Sello de la Oficina)

En Cádiz, a _____ de _____ de 20____

Fdo.:_____

Sr. Presidente de la Comisión Académica del Programa de Doctorado_____