



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY

Pronóstico satelital de la irradiación solar horaria a corto plazo mediante métodos de flujo óptico

Daniel Aicardi Vila

Programa de Posgrado en Ingeniería Eléctrica
Facultad de Ingeniería
Universidad de la República

Montevideo – Uruguay
Octubre de 2023



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY

Pronóstico satelital de la irradiación solar horaria a corto plazo mediante métodos de flujo óptico

Daniel Aicardi Vila

Tesis de Maestría presentada al Programa de Posgrado en Ingeniería Eléctrica, Facultad de Ingeniería de la Universidad de la República, como parte de los requisitos necesarios para la obtención del título de Magíster en Ingeniería Eléctrica.

Director:

Dr. Ing. Rodrigo Alonso Suárez

Director académico:

Dr. Ing. Pablo Musé

Montevideo – Uruguay

Octubre de 2023

Aicardi Vila, Daniel

Pronóstico satelital de la irradiación solar horaria a corto plazo mediante métodos de flujo óptico / Daniel Aicardi Vila. - Montevideo: Universidad de la República, Facultad de Ingeniería, 2023.

XIV, 116 p.: il.; 29,7cm.

Director:

Rodrigo Alonso Suárez

Director académico:

Pablo Musé

Tesis de Maestría – Universidad de la República, Programa en Ingeniería Eléctrica, 2023.

Referencias bibliográficas: p. 93 – 101.

1. pronóstico solar, 2. imágenes de satélite, 3. CMV, 4. flujo óptico, 5. GOES-East. I. Alonso Suárez, Rodrigo, . II. Universidad de la República, Programa de Posgrado en Ingeniería Eléctrica. III. Título.

INTEGRANTES DEL TRIBUNAL DE DEFENSA DE TESIS

Prof. Álvaro Gómez

Prof. Agustín Laguarda

Prof. Gonzalo Casaravilla

Montevideo – Uruguay
Octubre de 2023

A Melina, Paula y abuelo Mario.

Agradecimientos

Este es el momento en que uno se deja de tanto pronóstico y mira para atrás con mayor detalle. La culminación de la Maestría es un hito muy importante en mi desarrollo académico y personal el cuál no hubiera sido posible lograrlo solo. Más allá del deseo y la convicción de uno mismo, se necesitan personas que lo ayuden y lo orienten a uno a transitar el camino. Es importante saber qué y a quién escuchar, saber dónde está uno parado y a dónde quiere ir y evitar esos “eso no sirve para nada” que tantas veces escuché estos años.

El principal soporte que una persona tiene es su familia (natural o elegida). En este caso un agradecimiento especial para Melina que es mi faro y que ha estado en todo el camino en las buenas y en las malas y espero que siga mucho más. A Paula que sin quererlo me ha revolucionado la vida para bien.

Agradecer a mi segunda casa que es la UdelaR, a sus docentes. A la ANII y la Fundación Ricaldoni, ya que se han financiado algunos proyectos realacionados con la temática aquí tratada. Y a SCAPA-IE por la confianza y la paciencia.

Un especial agradecimiento a Rodrigo Alonso, por dirigir la tesis, por el compromiso (emociona encontrar correcciones hechas de madrugada), por el apoyo constante, por escucharme y por ser un ejemplo tanto personal como profesional. Agradecer a Pablo Musé (Director académico) por la orientación, por su rol docente y por siempre estar. Mi agradecimiento a Gonzalo Abal por ayudarme a dar los primeros pasos en la temática allá por el 2012 con el ingreso al grupo GMARS (Grupo de Modelado y Análisis del Recurso Solar) que luego se transformaría en el LES (Laboratorio de Energía Solar).

Hablar de Gonzalo Abal es también hablar del LES. El LES, primero bajo la dirección de Gonzalo y luego de Rodrigo a la actualidad, ha tenido una filosofía de trabajo que lo transforma, a mi entender, en uno de los mejores lugares para hacer investigación. El pilar fundamental es que se han logrado mantener grupos de trabajo estable en los años acumulando así conocimiento y mejorando las relaciones humanas. Todo esto se ve reflejado en la apertura del grupo a nuevas temáticas de estudio lo que lo ubica como centro de referencia en distintas temáticas en la región. Todo esto en una década. Mi agradecimiento a todos los compañeros del LES por siempre estar. Es un orgullo pertenecer a este gran grupo. Este documento refleja un trabajo que es la continuación de muchos otros y que será precursor de muchos más en el universo LES estoy seguro.

Mi agradecimiento a Mauricio que por trabajar al lado mio, se ha tenido que aprender la temática y me ha tenido que escuchar y ver tropezar una y otra vez.

A Aníbal y Esteban por el apoyo incondicional.

El paseo claro que valió la pena.

*...el futuro es así un
caleidoscopio de dudas y al
menor movimiento el lindo
pronóstico se vuelve mal
agüero...*

Mario Benedetti
(Hombre que mira sin sus
anteojos)

RESUMEN

La incorporación de fuentes de energía renovables a la generación eléctrica es una necesidad para descarbonizar el uso de energía. Una alta penetración de la energía solar fotovoltaica en las redes eléctricas requiere de herramientas adecuadas para la mitigación de su intermitencia solar. La predicción de la energía solar al corto y muy corto plazo es una herramienta de suma importancia para la planificación del despacho eléctrico, y para fijar precios y cantidades de venta de energía en un mercado eléctrico. Un incremento significativo de esta fuente de generación trae aparejado un cambio en cómo se gestiona esta energía, debido principalmente a la variabilidad del recurso a causa de la nubosidad. Para el pronóstico solar intra-día la mejor estrategia es la predicción en base a imágenes de satélite. Esta técnica presenta mejor desempeño que los modelos numéricos de atmósfera para horizontes de hasta 4-5 horas.

El presente trabajo se centró en el pronóstico satelital de la irradiación solar de muy corto plazo (de 1 a 5 horas) en base a imágenes del satélite geostacionario GOES-13 para una amplia región sudamericana que contiene a Uruguay. La etapa principal del pronóstico es la estimación del movimiento de las nubes. Para ello se implementó y evaluó un método tradicional y cuatro alternativas de estimación de movimiento por flujo óptico. La extrapolación del movimiento permite predecir la posición futura de las nubes y, por tanto, la irradiación solar a nivel de superficie. Se analiza el desempeño de los métodos en todas las etapas, desde el pronóstico de imágenes futuras hasta la predicción de irradiación solar. Se optimizan varios aspectos de los métodos, brindando los parámetros óptimos para la región. La evaluación de desempeño se realiza contra las mediciones terrestres de la red de medida del Laboratorio de Energía Solar distribuidas en varios puntos de nuestro país. Se observa un mejor desempeño de estos métodos en comparación con el tradicional. El método TVL1 de flujo óptico se identifica como el de mejor desempeño. Este es el primer trabajo a nivel internacional en establecer una comparación justa entre estas técnicas ante un mismo conjunto de datos.

Palabras claves:

pronóstico solar, imágenes de satélite, CMV, flujo óptico, GOES-East.

Tabla de contenidos

Lista de figuras	XII
Lista de tablas	XIV
1 Introducción	1
1.1 Generación solar en Uruguay	2
1.2 Predicción de la disponibilidad solar	4
1.3 Sobre esta tesis	7
2 Predicción de irradiación solar por satélite	9
2.1 Métodos para estimación de CMV	13
2.1.1 Algoritmo PIV	18
2.1.2 Flujo óptico	20
2.2 Métricas de desempeño	28
2.2.1 Definición de la persistencia	29
2.3 Desempeño en trabajos previos	33
3 Datos e implementación	36
3.1 Datos	36
3.1.1 Imágenes satelitales	37
3.1.2 Medidas en tierra	41
3.2 Pronóstico de las próximas imágenes	43
3.2.1 Estrategias para construir la imagen destino	45
3.3 Optimización de parámetros	47
3.4 Pronóstico de GHI	48
3.4.1 CIM-ESRA	50
4 Resultados	52
4.1 Conjuntos de datos	52

4.2	Optimización	53
4.3	Estrategias de extrapolación	55
4.4	Evaluación a nivel de imagen	56
4.5	Evaluación a nivel de GHI	59
4.5.1	Predicción a nivel de píxel	60
4.5.2	Incorporación de suavizado	61
4.5.3	Impacto del suavizado	66
4.5.4	Desempeño discriminado	68
4.5.5	Casos de estudio	78
4.6	Síntesis general del método	88
5	Conclusiones	90
	Referencias bibliográficas	93
	Glosario	102
	Apéndices	106
	Apéndice A Modelo de cielo claro ESRA	107
	Apéndice B Solución del método HS.	109
	Apéndice C Solución del método TVL1	111
	Apéndice D Suavizado a nivel de imagen	115

Lista de figuras

1.1	Potencia eléctrica instalada en Uruguay por fuente	3
1.2	Potencia microgeneración solar instalada en Uruguay por sector	3
1.3	Técnicas para el pronóstico de irradiación solar.	5
1.4	Aplicaciones del pronóstico solar.	7
2.1	Imagen del canal visible C02 del satélite actual GOES16	11
2.2	Etapas para el pronóstico satelital de irradiación solar.	12
2.3	Ejemplo de estimación satelital del CMV	17
2.4	Esquema Lorenz	19
2.5	Estructura piramidal	22
2.6	Índice de cielo claro respecto al tiempo - k_c	31
2.7	Persistencia convexa - $\gamma(h)$	32
2.8	Desempeño intra-día modelos numéricos globales ECMWF y GFS.	33
2.9	Comparación de desempeño entre pronóstico CMV y NWP.	35
3.1	Ubicación y ejemplo de las imágenes obtenidas del <i>GOES-East</i> .	38
3.2	Imágenes descartadas por píxels faltantes.	39
3.3	Región de control.	39
3.4	Ubicación de las estaciones terrestres.	41
3.5	Alternativas para pronosticar I_k	44
3.6	Estrategia OW.	46
3.7	Estrategias DN y DL.	47
3.8	T_L diario.	51
4.1	RMSD relativo respecto a parámetros.	54
4.2	Mejor ventana - Estrategia OW.	56
4.3	RMSD relativo en diferentes estrategias de extrapolación.	57
4.4	Desempeño de pronóstico a nivel de imagen.	58

4.5	RMSD relativo contra albedo.	59
4.6	Desempeño de pronóstico GHI.	60
4.7	Desempeño de pronóstico GHI.	62
4.8	Tamaño óptimo de ventana de suavizado (l).	63
4.9	Desempeño de pronóstico GHI con suavizado.	65
4.10	Desempeño predicción TVL1.	67
4.11	Diagramas de dispersión del pronóstico (h=1, estación LE).	68
4.12	Diagramas de dispersión del pronóstico (h=3, estación LE).	69
4.13	Diagramas de dispersión del pronóstico (h=1, estación LE).	70
4.14	MBD relativo discriminado (h=1, estación LE).	72
4.15	MBD relativo discriminado (h=3, estación LE).	73
4.16	MBD relativo discriminado (h=5, estación LE).	74
4.17	RMSD relativo discriminado (h=1, estación LE).	75
4.18	RMSD relativo discriminado (h=3, estación LE).	76
4.19	RMSD relativo discriminado (h=5, estación LE).	77
4.20	Pronóstico de GHI día 11/02/2016 con inicio hora 7:00.	79
4.21	Pronóstico de GHI día 11/02/2016 con inicio hora 8:00.	80
4.22	Pronóstico de GHI día 11/02/2016 con inicio hora 11:00.	81
4.23	Pronóstico de GHI día 11/11/2016 con inicio hora 7:00.	82
4.24	Pronóstico de GHI día 11/11/2016 con inicio hora 11:00.	83
4.25	Pronóstico de GHI día 16/11/2016 con inicio hora 11:00.	84
4.26	Pronóstico de GHI día 14/11/2016 con inicio hora 11:00.	85
4.27	Pronóstico de GHI día 24/10/2016 con inicio hora 8:00.	86
4.28	Pronóstico de GHI día 24/10/2016 con inicio hora 11:00.	87
4.29	Etapas del sistema general, incluyendo la etapa de suavizado.	89
D.1	Suavizado a nivel de imagen	115
D.2	Desempeño a nivel de imagen con suavizado	116
D.3	Desempeño a nivel de imagen con suavizado (TVL1 y LK-afn).	116

Lista de tablas

3.1	Distribución de imágenes disponibles año 2016.	40
3.2	Distribución de imágenes disponibles año 2017.	41
3.3	Resumen y detalles de estaciones terrestres.	42
3.4	Parámetros a optimizar en cada método.	47
3.5	Valores de a y b considerados por estación.	49
3.6	T_L mensual discriminado por zonas norte y sur.	50
4.1	Parámetros óptimos para cada método de estimación del CMV.	53
4.2	Desempeño de pronóstico a nivel de imagen.	57
4.3	Métricas de desempeño para pronóstico de irradiación solar.	61
4.4	Tamaño óptimo de ventana (px) de suavizado para cada método.	63
4.5	Tamaño óptimo de ventana (km) de suavizado para cada método.	64
4.6	Métricas de desempeño utilizando ventana fija de suavizado.	64
4.7	Métricas de desempeño utilizando ventana óptima de suavizado.	64

Capítulo 1

Introducción

El cambio climático es uno de los principales problemas que enfrenta la humanidad y el planeta, y resulta evidente la necesidad de acciones urgentes para disminuir sus efectos. La acción fundamental es la reducción global de emisiones de gases de efecto invernadero, especialmente el dióxido de carbono (descarbonización) en los sectores de energía, industria y transporte. En este escenario surge la necesidad del uso de energías de origen renovable. A nivel de la red eléctrica, la descarbonización requiere el aumento de la generación de origen renovable y una mayor eficiencia en el manejo de esta energía (despacho, almacenamiento, automatización, planificación, etc.) (Yang et al., 2022b).

La integración a gran escala de fuentes de energía renovables a estructuras preexistentes de provisión de energía eléctrica es uno de los mayores desafíos actuales y futuros (Lorenz et al., 2004, 2009; Ssekulima et al., 2016). Las fuentes de energía renovable de mayor crecimiento en el mundo son la eólica y la solar, y su integración es creciente, en especial en países donde la legislación o la decisión política incentiva a invertir en estas fuentes (Ssekulima et al., 2016). La Agencia de Energía Internacional (IEA) proyecta, para el año 2050 que entre un 15 % y 18 % de la electricidad mundial será por generación eólica y un 16 % por generación solar fotovoltaica (IEA, 2013, 2014). Alcanzar esta proyección requiere solucionar barreras tecnológicas asociadas a la intermitencia de estos recursos, lo cual conlleva variabilidad e incertidumbre. Conocer el recurso disponible y anticipar su comportamiento es fundamental en la medida en que estas fuentes renovables van aumentando su participación en la generación de electricidad. Para el año 2023, en el mundo, se esperan 250 GW de capacidad adicional fotovoltaica (PVPS, 2022). Además se estima que para el 2030 la

capacidad instalada de energía solar fotovoltaica supere a la hidroeléctrica y al gas natural (IEA, 2022).

Una forma de mitigar el efecto de la intermitencia del recurso variable consiste en anticipar el recurso a futuro. Esto es lo que se conoce como pronóstico o predicción. El pronóstico puede realizarse en distintos horizontes de predicción y con distinta resolución. El horizonte de predicción indica cuán a futuro se realiza la predicción, y la resolución su paso temporal dentro del horizonte. i.e. un pronóstico a una semana con paso diario. Los horizontes de predicción *al corto plazo* se pueden clasificar en intra-hora, intra-día o a varios días en adelante, lo que usualmente se denota respectivamente como ultra corto plazo, muy corto plazo y corto plazo¹. Esta tesis se centra en la predicción de irradiancia solar intra-día hasta 5 horas hacia el futuro con paso horario en base a imágenes de satélites geoestacionarios. Este tipo de predicción tiene aplicaciones al despacho eficiente de la generación eléctrica de origen solar. Algunas de las aplicaciones son el pre-despacho eléctrico y su replanificación, el manejo de las reservas del sistema, y su incorporación a estrategias de seguimiento de carga (McMahan et al., 2013; Coimbra et al., 2013).

1.1. Generación solar en Uruguay

En Uruguay, a partir de la política energética 2005-2030, se dio un gran impulso a la incorporación de fuentes renovables autóctonas a la matriz eléctrica nacional (OPP, 2019). Este impulso llevó a la generación solar a un incremento sustancial, dejando de ser marginal, pero aún pequeño en comparación a otras fuentes. En la Figura 1.1a se puede observar la evolución de la potencia instalada en el sector eléctrico, donde a partir de 2014-2015 se observa generación solar en operación (en amarillo). En la Figura 1.1b se observa la situación actual, estable desde hace algunos años, mostrando el porcentaje de cada fuente de energía respecto al total de potencia instalada; se observa que la fuente solar representa aproximadamente un 5%. Además se puede notar un crecimiento constante desde 2014 de la microgeneración en Uruguay (Figura 1.2), donde el mayor crecimiento se da en el sector Comercial. Este crecimiento fue debido a la inclusión de reglamentación del intercambio de energía en forma bidireccional con la red de distribución (decreto 173/010). Este decreto con-

¹Esta última denominación subjetiva puede variar dependiendo del área de conocimiento.

templa el uso de solar, eólica, pequeñas centrales hidroeléctricas, y biomasa, aunque por practicidad de las instalaciones el mayor crecimiento se dio en la tecnología solar fotovoltaica. El crecimiento a nivel empresarial se explica con el decreto 02/012 que incluye exoneraciones fiscales a la inversión en energías renovables OPP (2019). Análisis recientes sobre la expansión óptima de la red eléctrica en Uruguay indican que la generación solar tendrá un rol destacado en la próxima expansión (Casaravilla y Caporale, 2022; Gurín et al., 2022), con un crecimiento significativo.

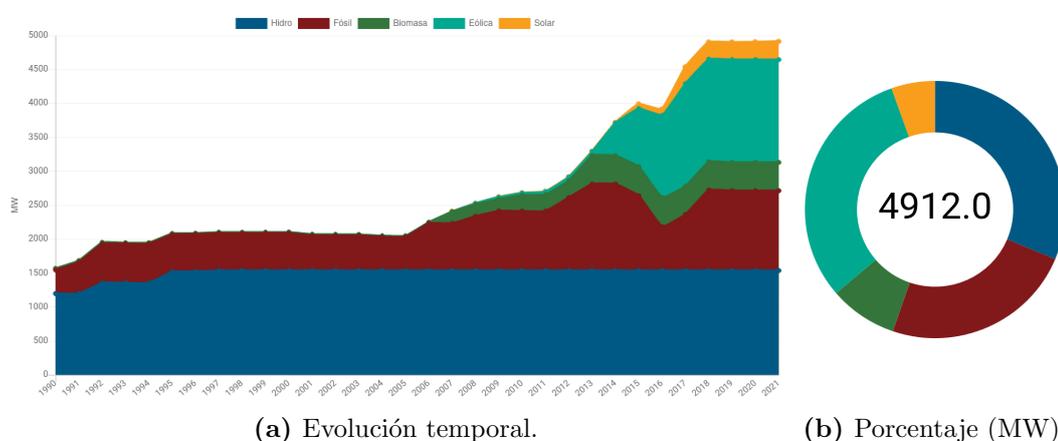


Figura 1.1: Potencia eléctrica instalada por fuente en Uruguay - Fuente: MIEM-BEN (Ministerio de Industria, Energía y Minería - Balance Energético Nacional) - <https://ben.miem.gub.uy/>

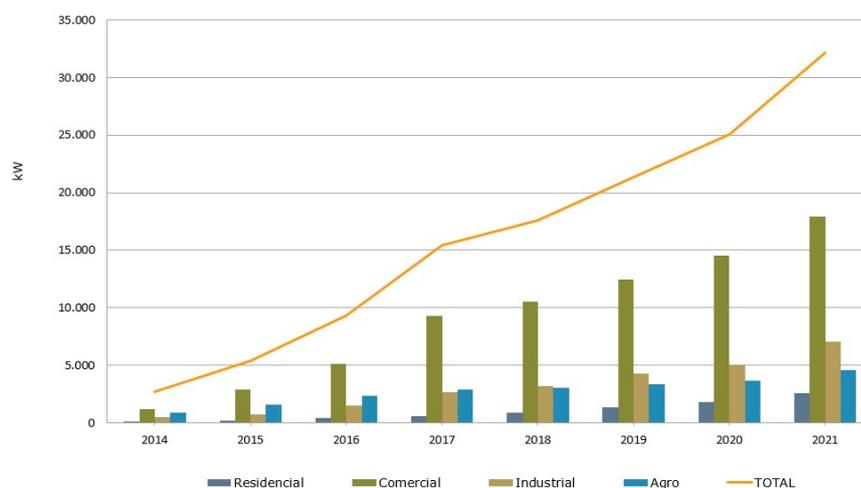


Figura 1.2: Potencia microgeneración eléctrica instalada por sector en Uruguay - Fuente: MIEM-BEN (Ministerio de Industria, Energía y Minería - Balance Energético Nacional) - <https://ben.miem.gub.uy/>

Este escenario de generación solar, en especial, los asociados a próximas expansiones significativas de la capacidad instalada de esta fuente, trae aparejado el desafío de manejar adecuadamente su intermitencia. Las herramientas de predicción a corto plazo son un elemento necesario para este fin.

1.2. Predicción de la disponibilidad solar

El recurso solar tiene dos fuentes de variabilidad: el movimiento aparente del Sol, de naturaleza geométrica y perfectamente predecible, y la variación en los constituyentes atmosféricos. De esto último, algunos varían en forma lenta, como los aerosoles, el vapor de agua y el ozono, afectando principalmente la disponibilidad en condiciones de cielo claro y de forma no crítica ($\simeq \pm 5\%$). En cambio, la nubosidad varía en forma rápida y produce fluctuaciones inciertas, que son de difícil predicción. En términos de disponibilidad, las fluctuaciones asociadas a la nubosidad son las principales, pudiendo provocar reducciones de hasta un 85-90% de recurso para un determinado sitio y momento. A su vez, éstas se traducen a la salida de generación de un parque solar fotovoltaico. Anticiparse a estos cambios rápidos y potencialmente importantes en la generación requiere, principalmente, pronosticar lo que va a suceder con las nubes en un entorno del sitio requerido.

Existen varias técnicas para el pronóstico de la irradiación solar, con diferentes características y uso específico. En [Kühnert et al. \(2013\)](#); [Coimbra et al. \(2013\)](#); [Diagne et al. \(2013\)](#) se agrupan las técnicas de pronóstico en cuatro grandes familias: los modelos numéricos de atmósfera (NWP, *Numerical Weather Predict*), la predicción por satélite, la predicción por cámaras todo-cielo ubicadas en tierra, y la predicción por herramientas de aprendizaje automático. Estas técnicas se pueden clasificar según la resolución espacial y temporal que alcanzan con desempeño competitivo. En la Figura 1.3 se muestra el lugar que ocupan las distintas formas de pronóstico a corto plazo en el espacio bi-variado (r, h) , donde r denota la resolución espacial (eje y) y h denota el horizonte de predicción (eje x). Para horizontes de pronóstico desde 6 horas en adelante, incluyendo varios días a futuro, los NWP son la única técnica posible. Estas predicciones pueden ser mejoradas por post-procesos de adaptación al sitio o regiones (mediante técnicas de series temporales o aprendizaje automático), o ser combinadas intra-día con información o predicción satelital. Cuando el horizonte de pronóstico es menor de 6 horas, la predicción

en base a imágenes satelitales es la dominante. La predicción satelital y por NWP pueden ser aplicadas a nivel de central fotovoltaica¹ ($\simeq 1$ km), de un entorno territorial a la planta ($\lesssim 100$ km) o a escala regional ($\lesssim 1000$ km). Por motivos prácticos, los diagramas como el de la Figura 1.3 se limitan a 100 km, pero nada impide que estas técnicas sean aplicadas por encima de dicha escala espacial. A medida que se baja el horizonte de predicción, aparecen otras técnicas como las cámaras todo-cielo y los modelos estadísticos. Estos últimos incluyen modelos de series de tiempo, como los procesos auto-regresivos, y herramientas de aprendizaje automático, como redes neuronales, máquinas de vector de soporte, entre otros, y no tienen una región bien acotada en el espacio bi-variado de la Figura 1.3 porque su desempeño depende fuertemente de las variables de entrada que utilicen. Las cámaras de cielo son la única técnica que alcanza alta resolución espacial (5-500 m) con aspiración de modelado “físico” del movimiento nuboso, en este caso, desde una estación en tierra. Para eventos casi instantáneos y localizados, la persistencia domina. La persistencia en el contexto de predicción solar se desarrolla en la Subsección 2.2.1.

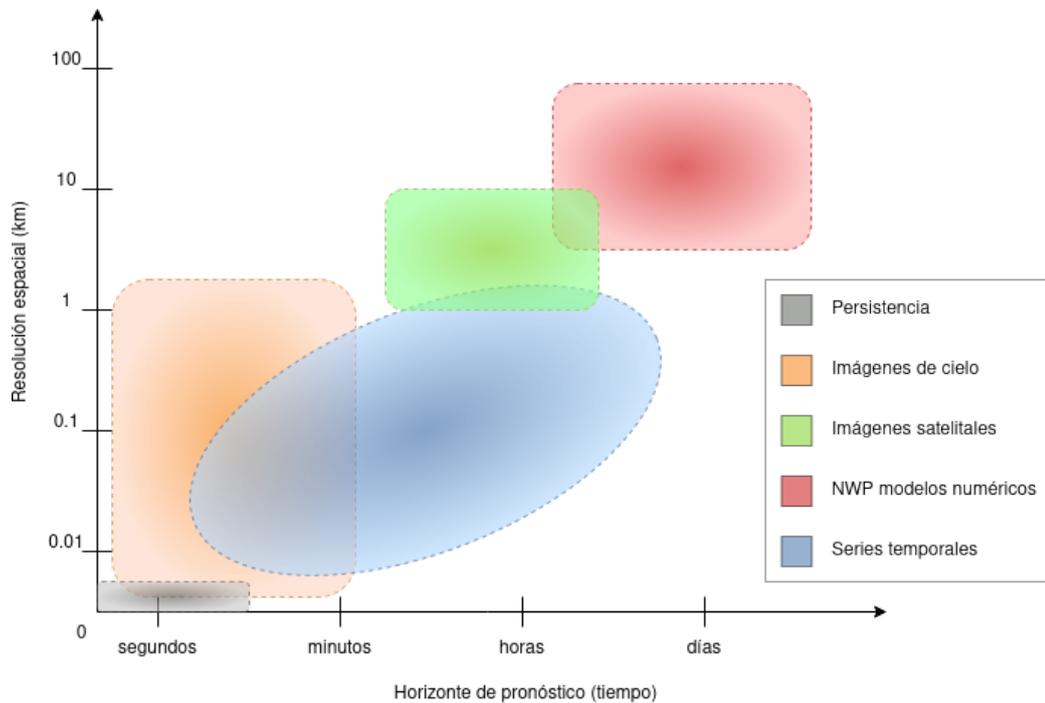


Figura 1.3: Capacidades espacio-temporales (r, h) de las técnicas para el pronóstico de irradiación solar. Adaptado de Diagne et al. (2013) y Ssekulima et al. (2016).

¹Como referencia, una central fotovoltaica de 50 MW ocupa un área de $\simeq 100$ hás = 1 km^2 , lo que es un píxel de 1×1 km en la imagen satelital.

La ubicación de las técnicas en el diagrama de la Figura 1.3, en especial los horizontes de pronóstico alcanzables, define su utilidad práctica para la operación de una red eléctrica, como se observa en la Figura 1.4. La planificación de la red eléctrica necesita pronósticos regionales de mediano plazo. La planificación de despacho (*unit commitment*) requiere información de pronósticos a varios días (intra-semana) con resolución horaria o diaria para que los algoritmos estimen la mejor combinación de fuentes para la generación eléctrica. Este es uno de los principales usos actuales del pronóstico. A medida que la fuente solar aumenta su participación relativa en la generación eléctrica, es necesario conocer los cambios del recurso a menor horizonte temporal para mantener el equilibrio entre la oferta y la demanda. Este equilibrio se logra con seguimiento de la demanda (*load following*) y buenas capacidades de predicción a corto plazo de las cantidades variables, incluyendo el recurso solar. De esta forma, el despacho de carga puede adelantarse a cambios no esperados por la planificación, y replanificar según la información intra-día más actualizada. Esto habilita a hacer un uso más eficiente de las reservas del sistema y de los generadores disponibles, y a hacer mejores intercambios regionales conociendo los excedentes. La capacidad de pronóstico es también importante para fines de un mercado eléctrico que funcione con acuerdos intra-día o de día previo, permitiendo fijar con menor incertidumbre precios y cantidades de venta. Para predicciones por debajo de los 30 minutos (por ejemplo, con resolución 10-minutal o minutal) existen aplicaciones más incipientes o de menor impacto, dado que en este espacio actúan los controles automáticos de la red eléctrica. Estas aplicaciones incluyen el control de la estabilidad de la red y regulación de tensión y frecuencia.

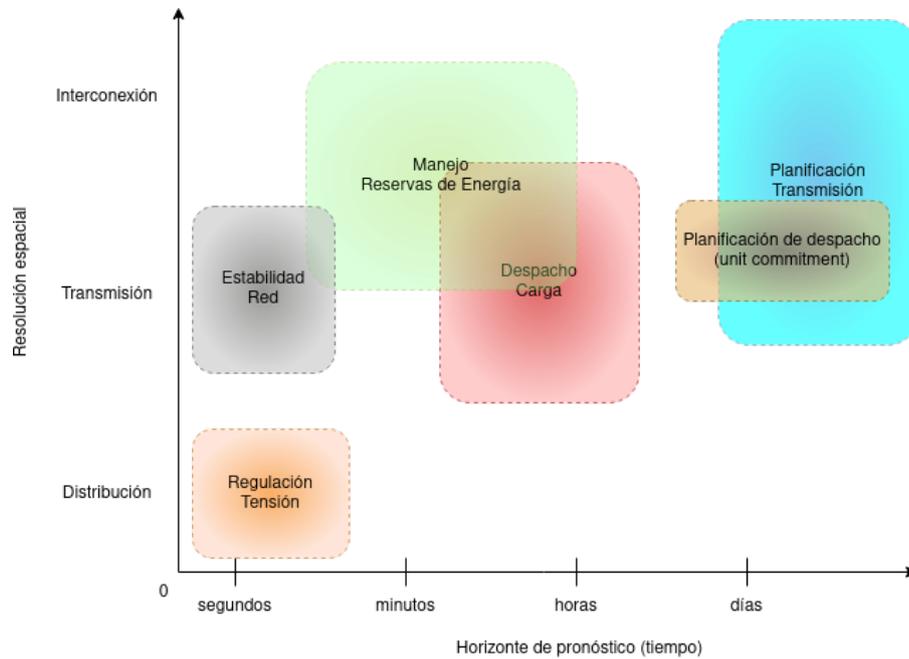


Figura 1.4: Aplicaciones del pronóstico solar. Adaptado de Ssekulima et al. (2016).

1.3. Sobre esta tesis

En este trabajo se desarrollan y validan algoritmos para el pronóstico de la irradiación solar a corto plazo, utilizando imágenes del satélite geostacionario *GOES-East* con cadencia temporal de 30 minutos. La variable a pronosticar es la irradiación global disponible en un plano horizontal a nivel de suelo. Se consideran los horizontes de pronóstico de 1 a 5 horas hacia el futuro con actualización cada 30 minutos, siendo éste un tipo de pronóstico intra-día. El trabajo se desarrolló en el Laboratorio de Energía Solar (LES, <http://les.edu.uy/>) de la UdelaR, que cuenta con mediciones terrestres en Uruguay y una base de imágenes de los satélites GOES que es única en el país. El objetivo de la tesis es evaluar métodos de flujo óptico (OF, *optical flow*) para la predicción del movimiento nuboso en imágenes de satélite y su aplicación a la predicción solar. Estos métodos son ampliamente utilizados en el campo de visión por computadora y su utilización para la predicción solar es incipiente, existiendo algunos pocos trabajos científicos dispersos en diferentes áreas geográficas y con distintas técnicas. Una virtud del presente trabajo es comparar para la predicción solar cinco técnicas de OF entre sí y con la técnica de uso más extendido (Lorenz et al., 2004) para una misma región geográfica, mismos conjuntos de entrenamiento y evaluación, y similares formas de optimización.

Los resultados presentados en este documento son una versión expandida y en español de la siguiente publicación generada en el marco de esta tesis.

- Aicardi, D., Musé, P., Alonso-Suárez, R. (2022). A comparison of satellite cloud motion vectors techniques to forecast intra-day hourly solar global horizontal irradiation. *Solar Energy*, 233, pp. 46-60. <https://doi.org/10.1016/j.solener.2021.12.066>.

Este documento está separado en capítulos que describen cada etapa del proceso, así como las herramientas requeridas para entenderlo. El estado del arte en la temática se presenta en el Capítulo 2. Esto incluye la descripción de los métodos para el cálculo del campo de desplazamientos en las imágenes de satélite (Sección 2.1), las métricas de desempeño específicas del área (Sección 2.2), y una síntesis de desempeño de la predicción solar por satélite y por modelos numéricos de atmósfera en los horizontes intra-día (Sección 2.3), que surge del análisis de trabajos previos internacionales y en la región. En el Capítulo 3 se describe la base de datos utilizada, compuesta de medidas en tierra e imágenes satelitales, y la metodología implementada, recorriendo la generación de imágenes pronosticadas, los parámetros a optimizar de cada técnica, y la forma en que se establece una predicción de irradiación solar horaria. Luego, en el Capítulo 4 se presentan y analizan los resultados obtenidos en cada etapa del pronóstico, tanto de desempeño como de optimización. Finalmente, las conclusiones y trabajo futuro se resumen en el Capítulo 5. Se incluyen además Apéndices con información, procedimientos y resultados más detallados.

Capítulo 2

Predicción de irradiación solar por satélite

La irradiancia solar es la potencia por unidad de área proveniente del Sol que incide en forma normal a una superficie dada. La irradiación es la integral en el tiempo de esta cantidad, es decir, la energía incidente por unidad de área. El pronóstico en el presente trabajo tiene granularidad horaria, por lo que las predicciones representan lo que va a ocurrir dentro de una hora dada, y pueden ser interpretadas como irradiación horaria (en Wh/m^2) o irradiancia promedio en una ventana de tiempo en W/m^2 (en el presente trabajo la ventana es de 1 hora.). La cantidad a pronosticar es la irradiación global sobre un plano horizontal a nivel de suelo (GHI, *Global Horizontal Irradiation*), que incluye a las componentes directa y difusa de la irradiación solar luego de su interacción con la atmósfera terrestre. A partir de un pronóstico de la GHI es posible construir (con buen desempeño) un correspondiente pronóstico de irradiación global sobre los paneles inclinados de una central PV (central fotovoltaica) utilizando modelos de separación (Gueymard y Ruiz-Arias, 2016; Abal et al., 2017) y transposición (Yang, 2016; Piccioli et al., 2018), y de generación PV utilizando un modelo de planta (Giacosa, 2020). Debido a lo anterior, y a que el LES cuenta con modelos de muy buen desempeño para la conversión de imágenes satelitales en GHI (Alonso-Suárez et al., 2012, 2014; Laguarda et al., 2020), este trabajo se centra en la predicción de dicha cantidad.

Las imágenes satelitales dentro del espectro visible (o del espectro solar) permiten distinguir la nubosidad diurna del terreno circundante. Esto excluye zonas con alto albedo superficial, como sitios nevados o salares, donde para ha-

cer la distinción es necesario además la información de los canales infrarrojos (Perez et al., 2013a; Dise et al., 2013). Este tipo de suelos no están presentes en la zona de trabajo (Pampa Húmeda sudamericana). En el caso de los satélites meteorológicos geoestacionarios, cuyos radiómetros poseen bandas en el espectro visible, esta identificación de nubes se puede hacer sobre amplias regiones territoriales, con resolución de entre 0.5 y 1.5 km, y con alta actualización temporal (entre 2 y 6 imágenes por hora). Un ejemplo de imagen del canal visible del actual satélite *GOES-East* (GOES16) se muestra en la Figura 2.1 (los contornos continentales y de países son adicionados en amarillo). Esta es una imagen conocida como “*full disk*” por registrar todo el disco terráqueo a la vista del satélite. Debido a que permiten identificar la nubosidad en alta frecuencia temporal y con tamaño de píxel del orden del tamaño de plantas PV, esta es la información utilizada para la predicción de irradiación solar y la estimación de irradiación ocurrida en sitios específicos o regiones territoriales.

El principal punto a resolver en el pronóstico satelital de irradiación solar es la estimación del movimiento de las nubes (Kühnert et al., 2013; Perez y Hoff, 2013). Esta estimación de movimiento se conoce como *Cloud Motion Vectors* (CMV) o *Cloud Motion Field* (CMF). Dadas dos imágenes consecutivas separadas un tiempo Δt (en este caso, de 30 minutos), se calcula el CMV asociado al movimiento de las nubes entre ambas escenas. Esto da como resultado que cada píxel tiene asociado un vector de movimiento. Como las nubes son el único elemento móvil en la secuencia de imágenes, se espera que los píxeles asociados al terreno estático de fondo tengan desplazamiento cero y que los píxeles con desplazamiento mayor que cero sean asociados a nubosidad en movimiento. Conocido el CMV, y suponiendo que su distribución espacial no cambia en el tiempo, se pueden predecir las imágenes a cada hora futura (en este caso, de 1 a 5 horas hacia adelante). El CMV, con la hipótesis planteada, indica hacia dónde se moverán los píxeles de la imagen actual hacia el futuro. Las imágenes pronosticadas a través del proceso de extrapolación del movimiento indican la posición futura de la nubosidad, a partir de la cuál es posible estimar GHI con modelos para este fin que son corrientes en el área de estimación de irradiación por satélite (Perez et al., 2002; Rigollier et al., 2004; Qu et al., 2017; Sengupta et al., 2018; Laguarda et al., 2020). El proceso completo se muestra, en forma esquemática, en la Figura 2.2 para el caso de pronosticar 5 valores a futuro, en este caso, cada una de las 5 horas.

El pronóstico por satélite es una tarea desafiante por varios motivos. En

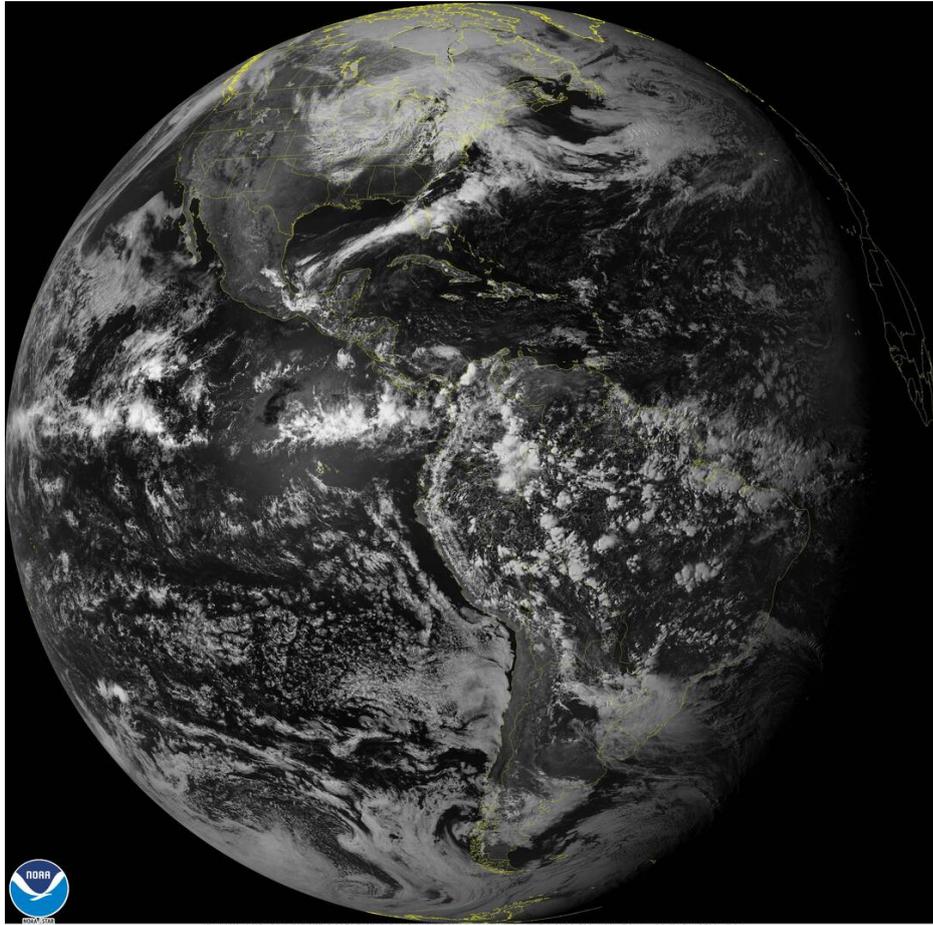


Figura 2.1: Imagen del canal visible (C02, centrado en $0.64 \mu\text{m}$, longitud de onda correspondiente al color Rojo) del satélite GOES16 en operación actual (ubicación geostacionaria *GOES-East*, -75°W sobre el ecuador terrestre). Imagen del 07/04/2022 19:30 UTC0 (16:30 en Uruguay, UTC-3).

primer lugar, las nubes no solo se trasladan, sino que también se forman, cambian de forma, y desaparecen, debido a una compleja dinámica atmosférica que el método no aspira a modelar, al menos no al estado del arte. Esto en parte se debe a que las imágenes son una visión bidimensional de un problema tridimensional y tienen información de la irradiación solar reflejada por los elementos en la escena, una variable física que es secundaria en el modelado de la evolución del estado de la atmósfera (su modelado no está integrado al núcleo central de los modelos de atmósfera, sino que se infiere luego de resolver la dinámica a través de parametrizaciones). Como resultado, el CMV que se estima por este método es bidimensional (x, y) e ignora el eje z , asumiendo implícitamente que localmente en el espacio la nubosidad se encuentra en el mismo plano de altitud. Esto hace que las técnicas sean incapaces de capturar

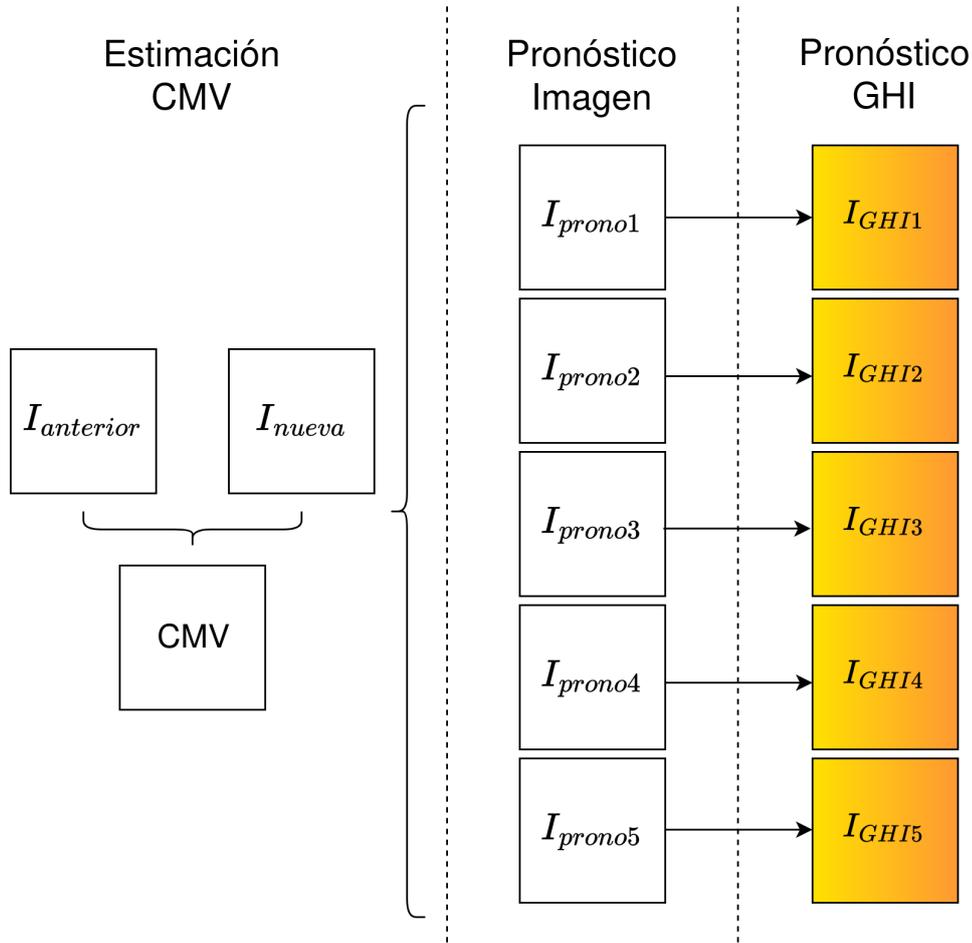


Figura 2.2: Etapas para el pronóstico satelital de irradiación solar.

fenómenos que involucren movimientos verticales de las nubes, en particular, los complejos procesos de convección. Lo anterior son limitaciones de la formulación del problema. Además de ellos, cada técnica de estimación del CMV puede agregar suposiciones adicionales para lidiar con la estimación de movimiento en la secuencia de imágenes. La extrapolación del movimiento presenta también sus simplificaciones. La principal en este sentido está asociada a asumir un CMV estático a través de los horizontes de pronóstico. Finalmente, los modelos de conversión a GHI tienen además una incertidumbre propia asociada, del orden del 12-15% en error cuadrático medio relativo (métrica de desempeño definida en Sección 2.2) para la conversión horaria a GHI a tiempo (t) (Laguarda et al., 2020), lo que establece un límite superior de desempeño para la predicción solar horaria. A pesar de estas simplificaciones, las técnicas satelitales han demostrado ser la mejor herramienta para la predicción de irradiación solar en los horizontes temporales de 1 a 5 horas, superando a las

predicciones por modelos numéricos de atmósfera y a los procedimientos de persistencia (Kühnert et al., 2013; Perez y Hoff, 2013; Alonso-Suárez et al., 2022).

En la Sección 2.1 se presentan los métodos de estimación del CMV considerados en el presente trabajo. Esto incluye la técnica más extendida y pionera en el área (Lorenz et al., 2004), utilizada como referencia, y cinco técnicas de estimación de flujo óptico propias del área de visión por computadora. La Sección 2.2 presenta las métricas de desempeño a utilizar, que son las clásicas del área de predicción solar determinística¹ (Yang et al., 2020) o puntual. Una métrica relevante es la “habilidad de pronóstico” (FS, *forecasting skill*), y su cálculo requiere definir un procedimiento de persistencia de referencia. Este procedimiento se explica en la Subsección 2.2.1. Finalmente, la Sección 2.3 presenta trabajos previos en el área, especialmente los que comparan el desempeño de la predicción satelital con la de modelos numéricos.

2.1. Métodos para estimación de CMV

Para detectar el movimiento de objetos en una secuencia de escenas es necesario, en general, que éstos se desplacen y deformen poco entre dos imágenes consecutivas. Esto normalmente se consigue con una separación temporal suficientemente chica. En otras palabras, la estimación de un CMV local en el tiempo requiere, idealmente, desplazamientos infinitesimales, y cuanto más cerca se esté de esa situación, mejor será la estimación. Los métodos suelen asumir también que las propiedades de un objeto en movimiento se mantienen esencialmente constantes cuando el desplazamiento es chico. Los métodos considerados en el presente trabajo imponen esto a través de la hipótesis de brillo constante, es decir, que el brillo observado no varía significativamente entre dos imágenes consecutivas cuyo movimiento intermedio se quiere estimar. Acercarse a esta propiedad en imágenes satelitales del canal visible implica realizar una normalización geométrica previo a su utilización, asociada a la iluminación espacialmente inhomogénea del Sol sobre la Tierra que resulta de su posición relativa. Esta normalización conduce al cálculo de la reflectancia planetaria (o albedo terrestre), que puede ser utilizada como una propiedad

¹Se utiliza este término “determinístico” en oposición a la predicción “probabilística”, que apunta a predecir las distribuciones de probabilidad futura y no sólo el valor puntual más probable, y por tanto tiene particularidades y métricas de desempeño distintas.

física del sistema Tierra-atmósfera con variación espacio-temporal rápida únicamente debido a la evolución de la nubosidad. Esta normalización se explica con mayor detalle en la Subsección 3.1.1.

Se debe dar un marco matemático formal para este problema. Sea $I : \mathbb{R}^3 \rightarrow \mathbb{R}$ la función que asigna un valor monocromático a cada píxel en una secuencia de imágenes. El valor monocromático es, en este caso, el albedo terrestre, en el intervalo $[0, 1]$. El dominio está representado por dos coordenadas espaciales (x, y) y una coordenada temporal (t) . Ω denotará la totalidad del dominio espacial de las imágenes. De esta forma, $I(x, y, t)$ representa la secuencia de imágenes a considerar. El movimiento entre dos imágenes consecutivas se representa como un campo vectorial $\vec{w} = (u, v)$, donde $u(x, y)$ y $v(x, y)$ son dos campos escalares que describen respectivamente la componente horizontal (dirección Este-Oeste) y vertical (dirección Sur-Norte) del movimiento (desplazamiento en píxeles). El objetivo de los métodos para la estimación del CMV bajo las simplificaciones expresadas anteriormente es estimar \vec{w} para cada pareja de imágenes consecutivas. Este vector representa el desplazamiento en píxeles entre imágenes consecutivas separadas en el tiempo Δt .

En el marco anterior, la hipótesis de brillo constante para dos imágenes separadas por una variación de tiempo pequeño no infinitesimal Δt se expresa según la Ec. 2.1.

$$I(x, y, t) = I(x + u, y + v, t + \Delta t) \quad (2.1)$$

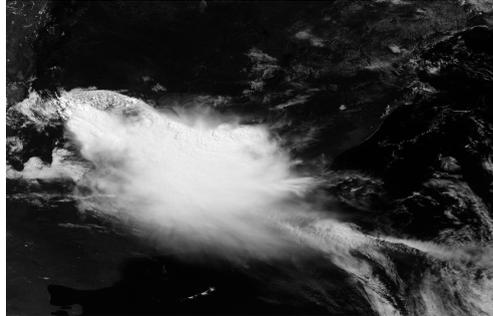
En secuencias reales esta hipótesis no es estricta, sino buscada, y se resuelve como un problema de optimización donde debe considerarse además información de los píxeles vecinos y/o restricciones sobre el CMV. Cuando u y v toman valores discretos, la ecuación anterior implica la relocalización de píxeles en la imagen. No obstante, muchos de los métodos para la estimación del CMV dan como resultado una relación de sub-píxel, es decir, campos escalares no enteros. Esto da lugar a que a un píxel en la segunda imagen no le tiene por qué corresponder exactamente un píxel en la primera (y viceversa). Otra forma de ver esta transformación es que la secuencia de imágenes se puede escribir como $I(x(t), y(t), t)$, donde $(x(t), y(t))$ es la trayectoria de un punto dado.

Existen varios trabajos sobre predicción solar satelital en base a la estimación de un CMV (Lorenz et al., 2004; Peng et al., 2013; Cros et al., 2014; Nonnenmacher y Coimbra, 2014; Chow et al., 2015; Urbich et al., 2019; Kallio-Myers et al., 2020; Aicardi et al., 2022; Roy et al., 2022). El método de Lorenz

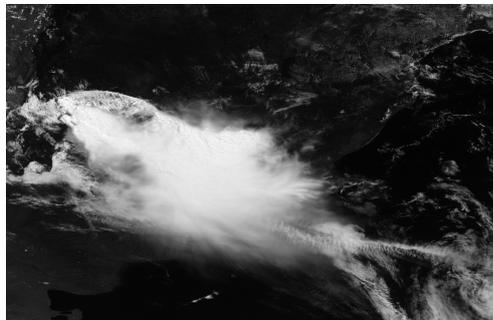
et al. fue la primer aplicación de este método para la predicción solar. El algoritmo se explica en la Subsección 2.1.1, e implementa un método conocido como block-matching en el campo de visión por computadora. En el campo de dinámica de los fluidos, existe el método PIV (*Particle Image Velocimetry*) (Adrian, 1991) que permite visualizar el flujo agregando partículas a un fluido y que en una de sus variantes implementa métodos de block-matching¹. Este algoritmo simple fue el primero en demostrar mejor desempeño para la predicción solar que los modelos numéricos. En Cros et al. (2014) se propone la utilización de un algoritmo de correlación de fase utilizado para aplicaciones de compresión de video (Kuglin y Hines, 1975). No se encontró en este trabajo una mejora respecto al algoritmo de *block-matching*. El resto de los trabajos aplican diferentes técnicas de Flujo Óptico (OF, *optical flow*, Subsección 2.1.2) para la predicción solar satelital. Estas técnicas incluyen los algoritmos de Lucas y Kanade (1981); Horn y Schunck (1981); Farnebäck (2003); Zach et al. (2007) que se consideran en este trabajo y se presentan en sendas Subsecciones en lo que sigue. El único trabajo, a la fecha, que provee una comparación de desempeño de varias técnicas para un mismo período temporal, conjuntos de entrenamiento y validación, y región territorial, es el presente trabajo, cuyo reporte científico se realizó en Aicardi et al. (2022).

Un ejemplo de estimación del CMV a partir de dos imágenes consecutivas puede verse en la Figura 2.3. Se puede observar que el campo de desplazamientos es nulo en los lugares donde hay terreno de fondo y presenta movimiento donde hay nubosidad. La figura ilustra también la complejidad de esta estimación, en tanto no todos los vectores son concordantes, habiendo fenómenos locales que afectan la estimación en su entorno. Además se agrega la información de diferencia absoluta con el fin de distinguir ambas imágenes consecutivas.

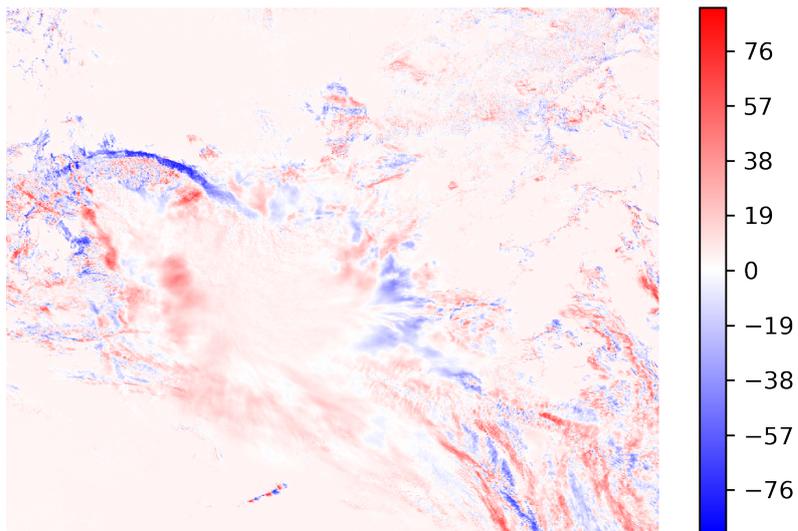
¹en el presente trabajo cada vez que se nombre PIV, se estará refiriendo a la implementación con block-matching



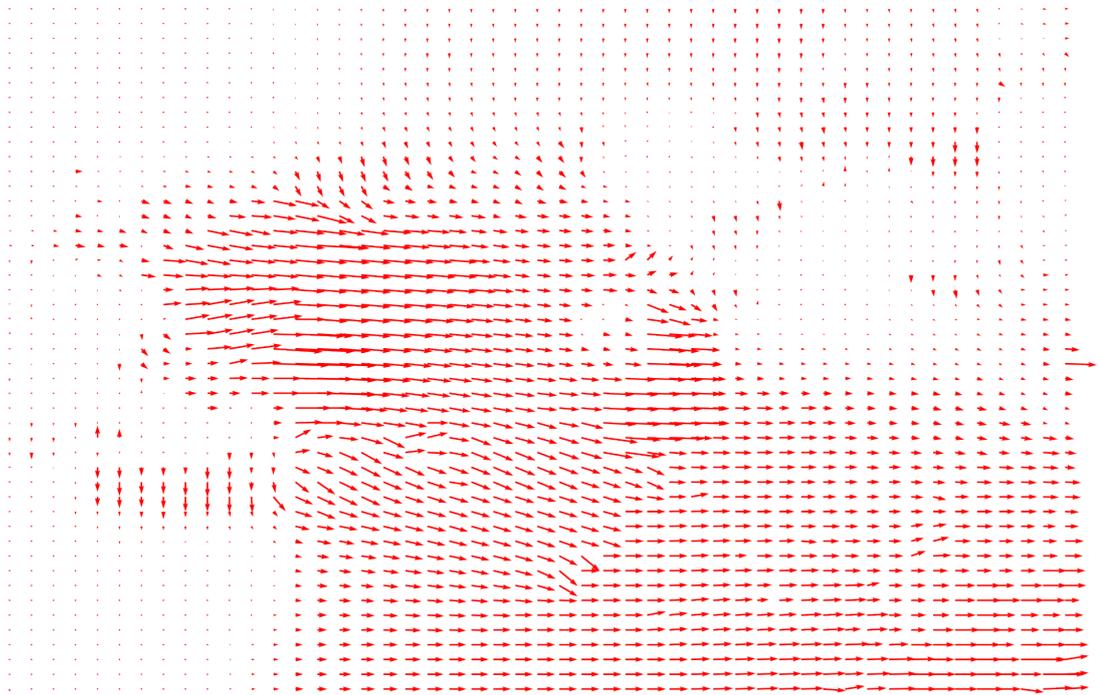
(a) Imagen $I(x, y, t)$.



(b) Imagen $I(x, y, t + \Delta t)$.



(c) Diferencia entre imágenes consecutivas (% de albedo).



(d) Estimación del CMV.

Figura 2.3: CMV estimado a partir de las dos imágenes consecutivas ($\Delta t = 30$ min).

2.1.1. Algoritmo PIV

Este método se basa en comparar bloques entre dos imágenes consecutivas para encontrar las más similares (Lorenz et al., 2004). Es uno de los métodos más simples, de utilización extendida, y ha sido utilizado para la operación del sistema eléctrico alemán (Kühnert et al., 2013). En la Figura 2.4 se muestra un esquema del funcionamiento del algoritmo, considerando la imagen actual $I_k = I(x, y, t)$ y la anterior $I_{k-1} = I(x, y, t - \Delta t)$. En la secuencia temporal, estas dos imágenes son, respectivamente, la imagen destino y origen.

Para un píxel dado en la imagen origen (píxel origen) se toma un entorno cuadrado (de tamaño $w_n \times w_n$) que lo tiene como centro (bloque origen). Se realiza una búsqueda del bloque origen en una ventana de búsqueda en la imagen destino (de tamaño $w_s \times w_s$). Por esta razón $w_n < w_s$. La búsqueda se realiza para píxeles dentro de la ventana de búsqueda que son centro de un bloque de igual tamaño al bloque origen, lo que permite una comparación píxel a píxel dentro de los bloques. A medida que se recorre la ventana de búsqueda con estos bloques, se evalúa la correlación entre destino y origen. Se considera que el máximo de correlación ocurre cuando se encuentra el bloque origen más similar al bloque destino, asociando la diferencia entre sus centros al desplazamiento buscado. Si esta diferencia se escala por el valor de Δt , se obtiene el movimiento en píxeles por minuto (px/min), que se asocia al vector de velocidad en (x, y) del píxel origen. El paso de búsqueda dentro de la imagen destino define el costo computacional del algoritmo. Tomar un paso de 1 px trae consigo un incremento apreciable del tiempo de cómputo. No se notaron diferencias en el desempeño para valores entre 1 y 30 px, considerando este último como valor a utilizar.

El procedimiento no busca coincidencias exactas de bloques sino que se busca el bloque más parecido al original. Esto es, se busca la hipótesis de brillo constante no en forma exacta, sino con una condición más relajada y que depende también de coincidencias en el entorno del píxel. Como resultado, se obtiene un CMV que no tiene un vector asociado a cada píxel debido al paso de búsqueda. Para completar un CMV denso, es decir, para cada píxel de la imagen, se realizó una interpolación bilineal del CMV en base a los que fueron calculados explícitamente. La búsqueda en la imagen destino podría no ser en una región acotada por w_s , pudiendo ser en toda la imagen, pero se estarían realizando operaciones innecesarias y a la vez se abriría la posibilidad de que

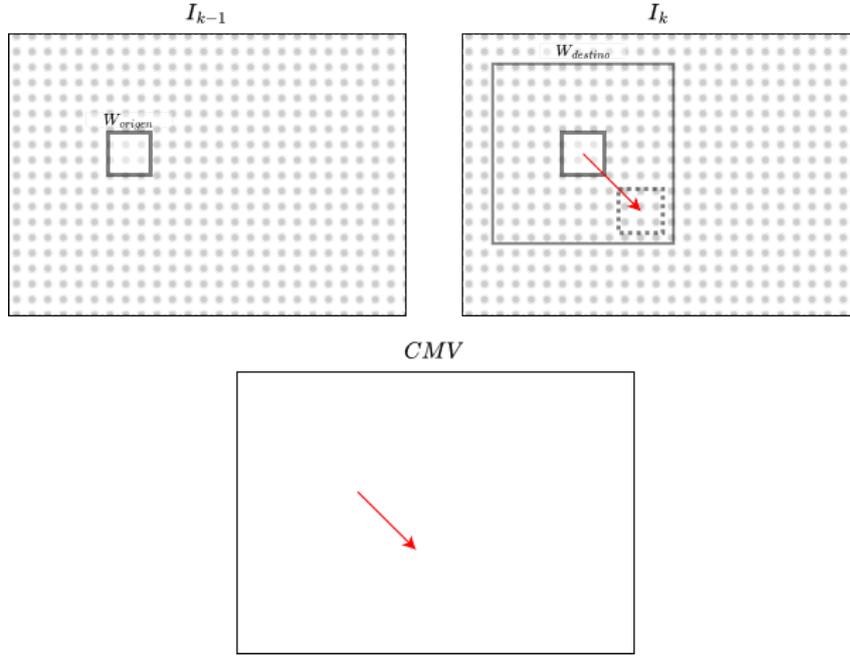


Figura 2.4: Esquema Lorenz. El subíndice k representa la imagen en la secuencia.

aparezcan vectores más grandes que lo físicamente posible (puede haber un sector alejado de la imagen donde haya mejor correlación por motivos espurios). Finalmente, se podrían usar otras métricas de similitud entre bloques diferentes a la correlación, como el error cuadrático medio, el desvío promedio, u otros indicadores de distancia estadística entre píxeles (por ejemplo, distancias entre distribuciones de probabilidad empírica). En el presente estudio, se aplicó la técnica según la implementación de [Lorenz et al.](#), utilizando la correlación como métrica de similitud.

Este método tiene por tanto dos parámetros a optimizar, w_n y w_s , cuyos resultados se presentan en la Sección 4.2. Para la implementación de este algoritmo de estimación de CMV se utilizaron funcionalidades de la biblioteca *Python* OpenPIV (<http://www.openpiv.net>). Este algoritmo fue implementado y evaluado previamente en la región en [Giacosa \(2020\)](#); [Giacosa y Alonso-Suárez \(2020\)](#). Dicha implementación se realizó con los parámetros w_n y w_s de la propuesta original del método, indicados de [Kühnert et al. \(2013\)](#), sin optimización local a la Pampa Húmeda.

2.1.2. Flujo óptico

El flujo óptico (OF por sus siglas en inglés) es, por definición, un método que evalúa los cambios entre dos imágenes consecutivas y es muy utilizado en el campo de la visión por computadora [Wedel y Cremers \(2011\)](#); [Davies \(2012\)](#). Un repaso por su evolución histórica a la actualidad se puede encontrar en [Fortun et al. \(2015\)](#). La hipótesis principal del OF es la hipótesis de brillo constante en desplazamientos infinitesimales. Con esta suposición, se tiene que:

$$I(x, y, t) = I(x + u.dt, y + v.dt, t + dt), \quad (2.2)$$

de donde realizando el desarrollo de Taylor de primer orden se obtiene la ecuación del flujo óptico:

$$I_x \cdot u + I_y \cdot v + I_t = 0, \quad (2.3)$$

donde I_x y I_y son las derivadas espaciales e I_t es la derivada respecto al tiempo. Notar que la interpretación de (u, v) aquí es el de un campo de velocidades, no el de un campo de desplazamiento.

Analizando la Ec. 2.3, el sistema lineal a resolver es indeterminado (tiene doble de variables que de ecuaciones, dado que por cada píxel a una ecuación y dos variables a determinar, u y v). La forma de resolver este problema es agregando condiciones de suavidad o regularidad al campo $\vec{w} = (u, v)$. Notar que la Ec. 2.3 es la linealización de la Ec. 2.2 y, por tanto, implica que los desplazamientos sean pequeños. Desplazamientos grandes hacen que los términos de orden superior de la serie de Taylor ya no sean despreciables respecto al término de primer orden y, al linealizar, se introduce más error. Una forma más compacta de expresar la Ec. 2.3 es:

$$\nabla I \cdot \vec{w} + I_t = 0 \quad (2.4)$$

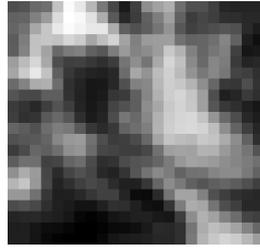
donde $\nabla I = (I_x, I_y)$ es el gradiente de la imagen.

Para poder utilizar con menor error la Ec. 2.2 en presencia de grandes desplazamientos se suele utilizar la estrategia piramidal ([Adelson et al., 1984](#)). Esta es una estrategia común que viene embebida en la implementación de las técnicas de OF, dado que permite lidiar mejor con secuencias reales. Esta estrategia se describe en detalle en [Wedel y Cremers \(2011\)](#); [Gonzalez y Woods](#)

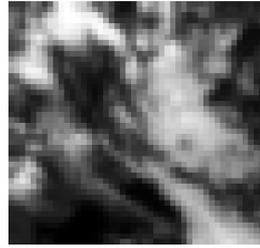
(2014); Meinhardt-Llopis et al. (2013); Wu et al. (2016), y consiste en el proceso iterativo que se comenta a continuación. En cierto paso del proceso iterativo, se tiene una imagen, se le aplica un filtro que suavice la imagen (en general, con un filtro gaussiano), luego se la submuestra (se le quitan filas y columnas) de acuerdo a un factor que en cada iteración es de 2^1 (en este caso se quitan por ejemplo las filas y columnas impares). El filtrado gaussiano se aplica para evitar el solapamiento de espectros (aliasing) al submuestrear (Meinhardt-Llopis et al., 2013) y se regula con un valor σ dependiente del factor de submuestreo. Este proceso se repite M veces (niveles). De esta forma, se tiene una estructura con M niveles sobre el piso (imagen original), definiendo una pirámide incremental (Figura 2.5). En el piso de más abajo se encuentra la imagen original y la imagen siguiente a cada piso es una versión suavizada y submuestreada del piso de abajo. A medida que se sube, se van filtrando los detalles de alta frecuencia de las imágenes resultantes (imágenes con menos resolución y suavizadas). Como se utiliza un factor de 2 para el submuestreo, cada piso tiene la mitad de resolución que la imagen del piso de abajo. De esta forma, un desplazamiento entre las imágenes originales se puede transformar en un desplazamiento ínfimo ($\times \frac{1}{2^M}$) si se considera una cantidad de niveles M suficiente y, por lo tanto, lidiar con el error dado por la linealización de la Ec. 2.2 en secuencias reales.

La estrategia consiste entonces en evaluar el CMV entre los pisos de las pirámides comenzando desde el piso superior (menor resolución) donde se cumple la condición de desplazamientos pequeños $\vec{w}_{(M)} = (u_{(M)}, v_{(M)})$. Luego se baja un piso y se utiliza el $\vec{w}_{(M)}$ calculado como un dato a priori del CMV a calcular. De esta forma, lo que se termina calculando en cada piso es el CMV residual ($\vec{r}_{(k)}$, que es pequeño si el dato a priori es cercano al valor óptimo) calculado a partir del conocido. La Ec. 2.5 calcula el desplazamiento en función del desplazamiento del piso superior y del desplazamiento residual a calcular dado el dato a priori. El factor 2 en el primer término es debido a que el CMV calculado en el piso superior es equivalente a un CMV del doble de valor en el piso inferior. También se debe comentar que para pasar de un CMV de una resolución a la del piso inferior, que es el doble, se agregan filas y columnas y se estiman sus valores realizando una interpolación (bilineal o bicúbica por lo general). En el piso de arriba sólo se calcula el residual ya que no se conocen valores a priori, y por tanto $\vec{w}_{(M)} = \vec{r}_{(M)}$. Teniendo en cuenta esto, se puede

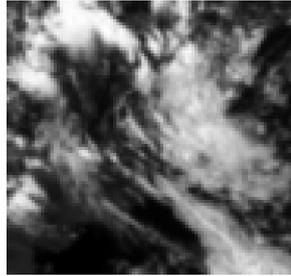
¹Lo más habitual es que se considere 2 como factor de submuestreo pero se puede utilizar cualquier otro.



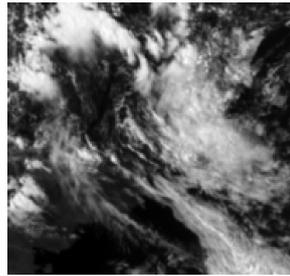
(a) $M = 6$, 22×23 px.



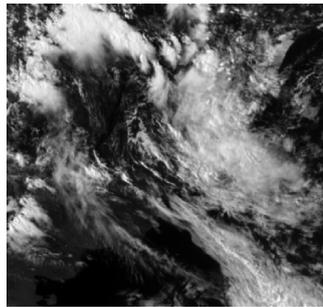
(b) $M = 5$, 44×46 px.



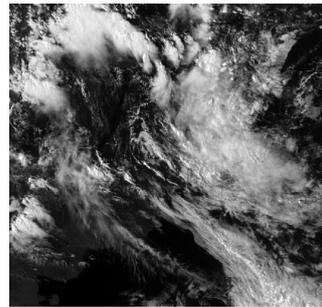
(c) $M = 4$, 88×92 px.



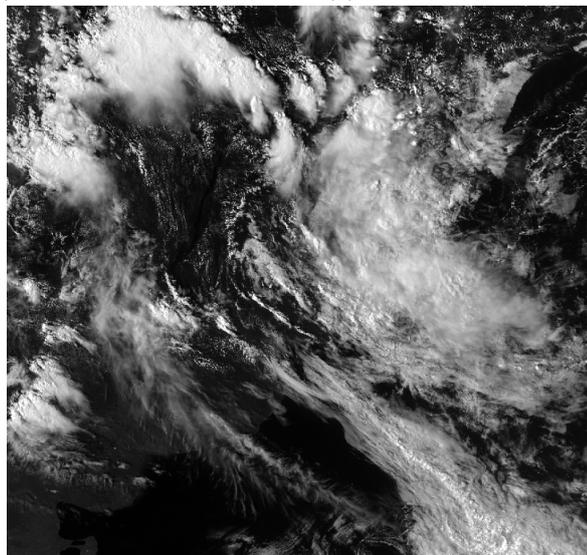
(d) $M = 3$, 175×184 px.



(e) $M = 2$, 350×367 px.



(f) $M = 1$, 699×734 px.



(g) $M = 0$, 1397×1467 px.

Figura 2.5: Estructura piramidal de 6 niveles con factor de submuestreo de 2.

calcular el CMV final (piso 0) como combinación ponderada de los residuales de cada piso según la Ec. 2.6.

$$\vec{w}_{(k)} = 2 \times \vec{w}_{(k+1)} + \vec{r}_{(k)} \quad (2.5)$$

$$\vec{w} = (u, v) = \vec{w}_{(0)} = \sum_{k=0}^M 2^k \times \vec{r}_{(k)} \quad (2.6)$$

En resumen, se obtiene un método iterativo que comienza calculando el desplazamiento en el piso superior y va bajando de piso alimentándose del valor a priori dado por el piso de arriba. En cada piso hacia abajo aparecen más detalles en las imágenes, lo que lleva a un ajuste del CMV final. Notar que objetos muy pequeños con grandes desplazamientos no se detectarán correctamente en este procedimiento, porque el proceso de reducción piramidal (submuestreo y suavizado) puede hacer que objetos pequeños desaparezcan. Esto no resulta una limitante a priori importante para el problema en cuestión, dado que las estructuras nubosas son extensas en el espacio, ocupando una buena porción de píxeles, y no píxeles aislados.

A continuación se describen específicamente los distintos métodos basados en flujo óptico empleados en el presente trabajo. Todos estos métodos implementan la estructura piramidal para contemplar grandes desplazamientos.

2.1.2.1. Lucas-Kanade (LK-avg y LK-afn)

Este es un método de regularización que considera las características locales del problema (Lucas y Kanade, 1981) para resolver la indeterminación de la Ec. 2.3. Aquí se consideraron dos variantes respecto a la forma del CMV en el vecindario de cada píxel. En ambas variantes se pueden formular como un problema de optimización local a cada píxel y conducen a resolver un sistema lineal que debe estar bien condicionado para su resolución.

La primera variante (LK-avg) supone que el CMV es constante en un entorno cuadrado \mathcal{W} alrededor de cada píxel, de tamaño $w \times w$ px, con w a determinar. La mejor solución es aquella que minimiza el error cuadrático medio de la Ec. 2.3 con u y v constantes dentro de cada entorno \mathcal{W} . Esto conduce al siguiente problema de optimización:

$$\arg \min_{u,v} \left\{ \int_{\mathcal{W}} (I_x \cdot u + I_y \cdot v + I_t)^2 \right\}. \quad (2.7)$$

La resolución del problema para cada píxel de la imagen (alrededor del cuál se toma una región \mathcal{W} centrada) lleva a w^2 ecuaciones que se resuelven por el método de mínimos cuadrados:

$$\begin{bmatrix} I_x^{(1)} & I_y^{(1)} \\ I_x^{(2)} & I_y^{(2)} \\ \vdots & \vdots \\ I_x^{(w^2)} & I_y^{(w^2)} \end{bmatrix} \cdot \begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} -I_t^{(1)} \\ -I_t^{(2)} \\ \vdots \\ -I_t^{(w^2)} \end{bmatrix}. \quad (2.8)$$

donde el superíndice indica el número de muestra dentro del entorno \mathcal{W} .

Para implementar este método se utilizó la función `CalcOpticalFlowLK` de la biblioteca *Python OpenCV 2*. Esta función no implementa la estrategia piramidal de resolución por lo que esta funcionalidad fue implementada por fuera, utilizando las funciones `pyrUp` y `pyrDown` de *OpenCV*.

La segunda variante (LK-afn) supone que en el entorno \mathcal{W} de cada píxel se puede encontrar una transformación afín entre las imágenes origen y destino. Se utiliza una transformación afín en la cual el CMV en el entorno se puede expresar como una función paramétrica $(u, v) = f(x, y, p)$, donde p es un vector de parámetros a resolver para cada entorno. El problema de optimización a resolver queda expresado por:

$$\arg \min_p \left\{ \int_{\mathcal{W}} (\nabla I \cdot f(p) + I_t)^2 \right\}, \quad (2.9)$$

$$f(p) = A(p) \cdot \vec{w}. \quad (2.10)$$

Expresando f de esta manera se impone una transformación afín lineal. Tomando un modelo de primer orden, la transformación se representa por 4 parámetros $p = (p_1, p_2, p_3, p_4)$, por lo que $A(p)$ toma la forma de:

$$A(p) = \begin{bmatrix} 1 + p_1 & p_2 \\ p_3 & 1 + p_4 \end{bmatrix}. \quad (2.11)$$

La resolución del problema lleva a una ecuación similar a la Ec. 2.8 a resolver por mínimos cuadrados para cada entorno \mathcal{W} , pero con cuatro parámetros (p_1, p_2, p_3, p_4) en lugar de dos (u, v) . Esto le da más grados de libertad a la regularización sobre cada entorno. La obtención del CMV en este segundo caso se

realiza evaluando la transformación afín en el píxel central de cada entorno. El tamaño w del entorno es un parámetro a optimizar, igual que en el caso anterior. No se exploraron en este trabajo transformaciones afines de mayor orden (que tienen asociado una mayor cantidad de parámetros). Se implementó este método con la función `calcOpticalFlowPyrLK` de la biblioteca *Python OpenCV* 3.x. Esta función ya implementa la estrategia piramidal.

2.1.2.2. Farnebäck (FRB)

En [Farnebäck \(2003\)](#) se propone una aproximación polinómica de segundo orden en el entorno de cada píxel. La intención de la propuesta es ser más robusto al ruido. Debido a esto, resulta un método razonable de implementar para este problema, dado que, desde el punto de vista del procesamiento de señales, las imágenes satelitales son propensas al ruido ([Peng et al., 2013](#)). El método de [Farnebäck](#) presenta cierta popularidad en las aplicaciones debido a su simplicidad de implementación y buena documentación en las bibliotecas de *OpenCV*. Este método fue utilizado para la estimación de CMV en [Kallio-Myers et al. \(2020\)](#), dando como resultado un CMV denso con bajo costo computacional.

Las aproximaciones locales son de la forma: $\chi^T \cdot A_i(\chi) \cdot \chi + b_i^T(\chi) \cdot \chi + c_i(\chi)$, donde $\chi = (x, y)$ contempla las dos coordenadas espaciales y el subíndice i diferencia las dos imágenes utilizadas para la estimación del campo. Notar que A , b , y c , dependen de la posición espacial. Se introducen dos cantidades para lidiar con la aproximación:

$$A(\chi) = \frac{1}{2}(A_1(\chi) + A_2(\chi)), \quad (2.12)$$

$$\Delta b(\chi) = -\frac{1}{2}(b_2(\chi) - b_1(\chi)), \quad (2.13)$$

lo que conduce a un sistema que se puede resolver por el método de mínimos cuadrados,

$$A(\chi) \cdot d(\chi) = \Delta b(\chi), \quad (2.14)$$

donde $d(\chi)$ es el CMV para cada píxel (en este contexto, un campo de desplazamiento). En su formulación estándar, el método incorpora la asignación de pesos $g(\chi)$ dentro del entorno \mathcal{W} como forma de asignar más importancia relativa a algunos píxeles frente a otros. Estos pesos están dados por una

función Gaussiana de media nula y desviación estándar a definir al inicio del algoritmo. La formulación estándar parametriza además el CMV con un modelo de desplazamiento lineal $d(\chi) = S(\chi) \cdot a$, similar a la transformación afín de [Lucas y Kanade](#), pero en términos de un vector de parámetros a . De esta manera, el problema de optimización queda dado por:

$$\arg \min_a \left\{ \int_{\mathcal{W}} g(\chi) \cdot [A(\chi) \cdot S(\chi) \cdot a - \Delta b(\chi)]^2 \right\} \quad (2.15)$$

donde

$$S(\chi) = \begin{bmatrix} 1 & x & y & 0 & 0 & 0 & x^2 & xy \\ 0 & 0 & 0 & 1 & x & y & xy & y^2 \end{bmatrix}, \quad (2.16)$$

$$a = (a_1, a_2, a_3, a_4, a_5, a_6, a_7, a_8)^T, \quad (2.17)$$

y se actualiza la Ec. 2.14 por el siguiente sistema a resolver para cada entorno:

$$g(\chi) \cdot S(\chi) \cdot A(\chi) \cdot a = g(\chi) \cdot \Delta b(\chi). \quad (2.18)$$

Con esta formulación, la estimación del CMV implica obtener los ocho parámetros a_i para cada entorno \mathcal{W} , de tamaño w a optimizar. Este método se implementó con la función `calcOpticalFlowFarneback` de la biblioteca *Python OpenCV* 3.x, que ya implementa la estrategia piramidal.

2.1.2.3. Horn-Schunck (HS)

Este es un método variacional donde se optimiza un funcional sobre toda la imagen ([Horn y Schunck, 1981](#)). El problema de optimización se formula de acuerdo a la Ec. 2.19. El CMV es aquel que minimiza una función de costo que contiene dos términos; un primer término que regulariza los gradientes del campo (∇u y ∇v), imponiendo condiciones de suavidad para el CMV, y un segundo término asociado a la ecuación de flujo óptico (2.3) (conocido como término de ajuste a datos). Ambos términos utilizan la norma \mathcal{L}^2 para penalizar los errores. El parámetro α controla el peso relativo entre ambos términos. Esto es, para α grandes, el peso del término de regularización es mayor que el del término asociado a la ecuación de flujo óptico, y como resultado se obtendrá un CMV más suave. Para α chicos sucede lo opuesto, obteniendo un CMV más variable (más ruidoso) pero donde el ajuste a datos será mejor. En el

Apéndice B se desarrolla con mayor detalle la solución a este problema.

$$\arg \min_{u,v} \left\{ \int_{\Omega} (I_x \cdot u + I_y \cdot v + I_t)^2 + \alpha \cdot [(\nabla u)^2 + (\nabla v)^2] \right\}. \quad (2.19)$$

Este método se implementó con la función `CalcOpticalFlowHS` de la biblioteca *Python OpenCV* 2.x. Esta función no implementa la estrategia piramidal por lo que se implementó de la misma manera que para el método LK-avg.

2.1.2.4. TVL1

Este método, al igual que el método anterior, se basa en la minimización de un funcional con dos términos sobre toda la imagen. Los métodos anteriores utilizan la norma \mathcal{L}^2 para ponderar los errores. Esto resulta en funcionales diferenciables y convexos cuya resolución se realiza con herramientas relativamente estándar, pero los hace sensibles a la presencia de *outliers*. Esto es, muestras aisladas que resultan en desvíos grandes pueden tener una influencia importante en la minimización. El uso de la norma \mathcal{L}^1 para el término de ajuste a datos permite mayor robustez ante este problema, pero resulta en un problema de optimización convexo no diferenciable. Esta última característica agrega importante complejidad a su resolución. Al mismo tiempo, es posible incorporar la regularización de Variación Total (TV) de [Rudin et al. \(1992\)](#) a los gradientes de u y v , lo que permite preservar mejor las discontinuidades en el CMV ([Wedel y Cremers, 2011](#)). Esto último ocurre en las secuencias de imágenes satelitales, por ejemplo, ante una interfaz entre el terreno y la nubosidad en movimiento, o cuando hay nubosidad a distinta altura moviéndose en distinta dirección dentro de un mismo entorno local. Las consideraciones anteriores llevan al siguiente problema de optimización,

$$\arg \min_{u,v} \left\{ \int_{\Omega} |\nabla u| + |\nabla v| + \lambda \cdot |I_x \cdot u + I_y \cdot v + I_t| \right\}, \quad (2.20)$$

donde λ controla el peso relativo entre ambos términos. Esta formulación es conocida como TVL1 ([Zach et al., 2007](#); [Sánchez et al., 2013](#)), y su solución es posible debido al desarrollo de métodos computacionales eficientes para la resolución de problemas convexos no diferenciables ([Chambolle, 2004](#)). La solución a este problema se detalla en el Apéndice C. La implementación utilizada es la propuesta en [Sánchez et al. \(2013\)](#), cuyo código está disponible en lenguaje C y fue adaptado al problema específico.

2.2. Métricas de desempeño

Para poder evaluar el desempeño del pronóstico, se deben comparar los valores pronosticados con los valores observados. Esta comparación se puede realizar a nivel de imagen (albedo terrestre), es decir, calculando métricas de la comparación píxel a píxel sobre toda la imagen, o a nivel de GHI en los sitios donde hay medidas terrestres de esta cantidad. Las métricas de desempeño son las mismas en ambos casos, con la diferencia que a nivel de imagen se calculan primero para cada imagen y luego se promedian sobre toda la secuencia de imágenes. Las métricas se calculan para cada uno de los horizontes de predicción horarios considerados en el presente trabajo.

Se utilizaron las métricas de desvío promedio (MBD, Mean Bias Deviation) y de error cuadrático medio (RMSD, Root Mean Square Deviation), según su definición usual:

$$\text{MBD} = \frac{1}{N} \sum_{i=1}^N (Y_{est} - Y_{obs}), \quad (2.21)$$

$$\text{RMSD} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{est} - Y_{obs})^2}. \quad (2.22)$$

Estas métricas se consideraron también en forma relativa al valor medio de las observaciones, pudiendo ser el valor medio de cada imagen o el valor promedio de la serie temporal de las medidas de GHI, según corresponda. Una forma de interpretar los resultados de RMSD relativo (rRMSD) a nivel de píxel (tamaño de una planta fotovoltaica) es definir la relación que vincula lo estimado con lo observado (ecuación 2.23).

$$Y_{est} = Y_{obs} \times (1 \pm rRMSD) \quad (2.23)$$

En la comunidad de predicción meteorológica es común comparar el desempeño contra procedimientos simples de referencia. La referencia usual es la persistencia, que consiste en asumir que las condiciones permanecerán estables hacia el futuro cercano. Es conocido que este procedimiento provee un límite de desempeño exigente en los horizontes de corto y muy corto plazo (Jolliffe y Stephenson, 2011). La comparación de desempeño contra el desempeño de la

referencia define la métrica de Habilidad de Pronóstico (FS, *forecasting skill*):

$$FS = 1 - \frac{RMSD_{prono}}{RMSD_{pers}} \quad (2.24)$$

Cuanto mayor sea el valor de FS, mejor desempeño del pronóstico. Valores positivos de FS indican un mejor desempeño que la referencia, y viceversa para valores negativos. Un FS = 100 % indica un pronóstico perfecto. Valores usuales de FS para la predicción solar rondan el 10-20 %.

El cálculo del FS supone definir un método de referencia. Este método será distinto para la evaluación a nivel de imagen y de GHI. Estos procedimientos se explican en la subsección a continuación.

2.2.1. Definición de la persistencia

Para saber si un método de pronóstico es bueno, debe ser mejor que un método de pronóstico de referencia que asume que no hay cambios en determinadas variables, es decir, estas variables persisten en el tiempo. Sea h el horizonte de pronóstico a considerar. En el caso de imágenes, refiere a la cantidad de imágenes a futuro, y en el caso de la serie temporal de GHI, refiere a h muestras hacia adelante.

2.2.1.1. Persistencia a nivel de imagen

La cantidad a persistir no debería tener variaciones conocidas o perfectamente predecibles en los horizontes de pronóstico, como sería el caso de la evolución geométrica conocida de cantidades asociadas a la irradiación solar. A nivel de imagen, debería proveer un valor de persistencia para cada píxel. La propia imagen satelital, en este caso, la reflectancia planetaria (ρ_p), cumple estos requisitos y sirve para establecer una referencia simple de persistencia. Esto se expresa, para todo h , como,

$$\hat{\rho}_p(x, y, t + h) = \rho_p(x, y, t). \quad (2.25)$$

Como las imágenes corresponden a esta cantidad, la ecuación anterior es lo mismo que imponer $\hat{I}(x, y, t + h) = I(x, y, t)$.

2.2.1.2. Persistencia a nivel de GHI

Para la GHI no es correcto establecer una persistencia como $GHI(t+h) = GHI(t)$. Esto se debe a que la GHI tiene una variación geométrica intra-día asociada a las condiciones de cielo despejado, y por tanto, una persistencia de esta forma incurre en desvíos anticipables. Se debe por tanto recurrir a una cantidad donde este comportamiento geométrico haya sido removido. La comunidad de predicción solar ha dedicado esfuerzos a definir procedimientos simples de persistencia que cumplan esta característica (Yang, 2019; Yang et al., 2020). Las referencias actualmente aceptadas se basan en el índice de cielo claro (k_c), una cantidad adimensionada y sin variación geométrica cuyas fluctuaciones representan variaciones en la nubosidad del cielo (Lauret et al., 2022). En los apartados que siguen, se definen las dos referencias utilizadas en el presente trabajo, que están basadas en este índice.

Persistencia del índice de cielo claro - k_c

El índice de cielo claro se define como el cociente entre la irradiación global sobre plano horizontal (GHI) y la irradiación que se tendría en caso de condiciones de cielo claro. Esta irradiación de cielo claro se debe modelar, existiendo varias alternativas para este fin (Rigollier et al., 2000; Lefèvre et al., 2013; Laguarda y Abal, 2016). En el presente trabajo se escogió el modelo de cielo claro ESRA (Rigollier et al., 2000), que fue identificado en Laguarda (2021) como el de mejor relación entre simplicidad y desempeño para la estimación de GHI de cielo claro en nuestra región. En la Figura 2.6 se muestra un ejemplo de cómo varía k_c en el tiempo en un sitio dado. Es importante notar la poca dependencia estacional y que aparecen valores mayores a uno, relacionados con la incertidumbre del método ESRA.

Por tanto, el índice de cielo claro se calcula como:

$$k_c(t) = \frac{GHI(t)}{GHI_{ESRA}(t)}, \quad (2.26)$$

y la persistencia por k_c queda definida como: $\hat{k}_c(t+h) = k_c(t)$. La GHI de persistencia se calcula entonces como:

$$GHI_{pers}(t+h) = k_c(t) \times GHI_{ESRA}(t+h), \quad (2.27)$$

donde $GHI_{ESRA}(t+h)$ se puede calcular a partir de la implementación del

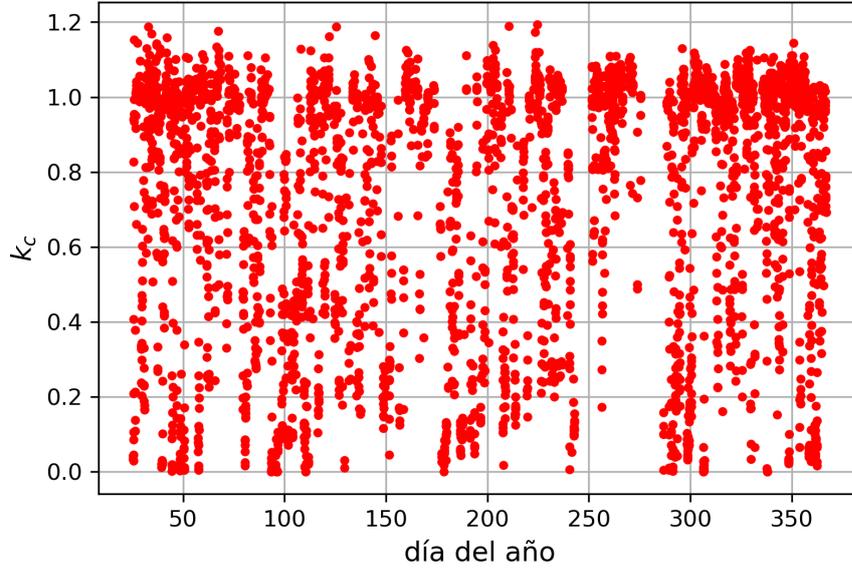


Figura 2.6: Índice de cielo claro respecto al tiempo - k_c .

modelo ESRA. La implementación de este modelo de cielo claro se presenta en detalle en el Apéndice A. Esta persistencia se utiliza en el presente trabajo como referencia dado que es el procedimiento aceptable más simple. No obstante, el procedimiento recomendado es la persistencia que se presenta en el próximo apartado, dado que provee un límite de desempeño más exigente.

Persistencia convexa - k_{cc}

En Yang (2019) se propone utilizar como procedimiento de referencia la combinación convexa entre persistencia en k_c y la climatología de k_c , caracterizada por la media (μ) y desviación estándar (σ) en un período de tiempo conocido, idealmente largo. Este procedimiento es conocido como persistencia convexa y queda definido por,

$$k_{cc}(t+h) = \gamma(h) \times k_c(t) + [1 - \gamma(h)] \times \mu, \quad (2.28)$$

donde $\gamma(h)$ es la auto-correlación de la serie de k_c :

$$\gamma(h) = \frac{\text{Cov}(k_c(t-h), k_c(t))}{\sigma^2}. \quad (2.29)$$

Para horizontes h pequeños (muestras más cercanas), la covarianza tiende a valores cercanos a σ^2 , y por lo tanto $\gamma \simeq 1$ y $k_{cc} \simeq k_c$. Con el mismo razonamiento, para horizontes h grandes, γ se hace pequeño y $k_{cc} \simeq \mu$. La

persistencia convexa por tanto busca representar a la persistencia en k_c para horizontes de pronóstico pequeños y a la climatología para horizontes de pronóstico más largos.

Un análisis comparativo entre distintas formas de persistencia (incluyendo la persistencia en k_c) y la combinación convexa para esta región se puede ver en [Alonso-Suárez et al. \(2021\)](#). En este trabajo se observa que la persistencia convexa es la más exigente en términos de RMSD, algo que se constata también en la presente tesis. En dicho trabajo se observa también que la sensibilidad de la persistencia convexa al utilizar muestras de uno u otro año para el cálculo de γ es baja. Esto se muestra en la Figura 2.7, comparando los valores de $\gamma(h)$ para los años utilizados en el presente trabajo (2016 y 2017). Debido a esto, no es crítico la elección del período durante el cuál se calcula μ y $\gamma(h)$ para la persistencia convexa. En el presente trabajo se utilizó el año 2016 (año de evaluación), de modo de generar un límite de desempeño un poco más exigente que si se utilizara el año 2017 (año de entrenamiento).

Para evaluar el desempeño a nivel de GHI, se utilizarán la persistencia en k_c y la persistencia convexa. La primera es menos estricta, pero es la estrategia más difundida y contra la cual se solía comparar en el pasado y por lo tanto está presente en el análisis.

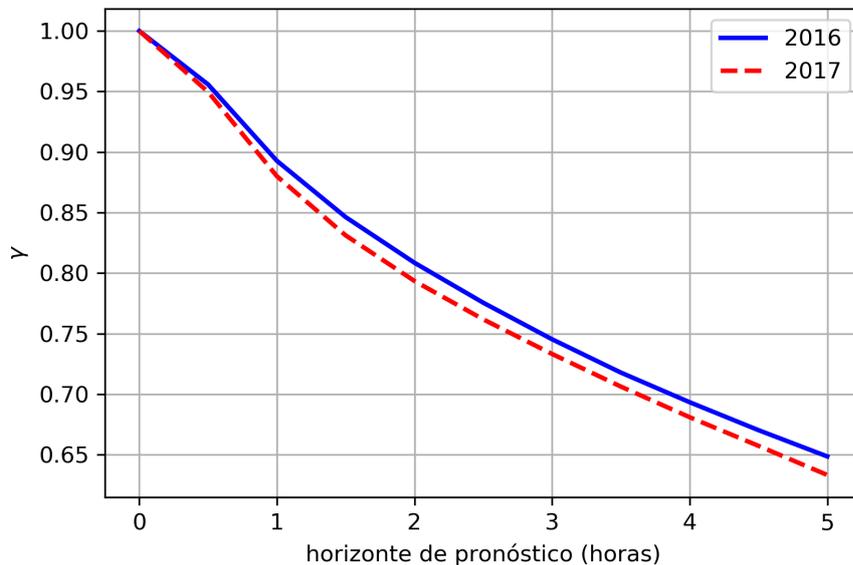


Figura 2.7: Comparativa de $\gamma(h)$ para el calculo de la persistencia convexa.

2.3. Desempeño en trabajos previos

Esta sección busca dar una referencia de desempeño en la región y hallazgos previos en otros trabajos, específicamente en la comparación de la predicción satelital con la de modelos numéricos de atmósfera. Esta comparación se realiza en los horizontes intra-día, donde ambas técnicas de predicción co-existen.

En [Teixeira-Branco et al. \(2021\)](#) y [Teixeira-Branco et al. \(2022\)](#) se analiza el desempeño de dos NWP globales, el ECMWF (*European Centre for Medium-Range Weather Forecasts*) y GFS (*Global Forecast System*), para el pronóstico intra-día de irradiación solar en la región Pampa Húmeda. Se evalúa el pronóstico numérico de las primeras 24 horas que inicia a generarse a la hora 00 UTC y que está disponible al inicio del día, cercano a las 06 UTC. Se encontraron RMSD relativos hora a hora entre 24.9% y 33.7% (28.3% promedio) para el ECMWF y entre 27.2% y 39.3% (32.8% promedio) para el modelo GFS. Estos valores se ilustran en Figura 2.8. De estas evaluaciones también se puede notar que estos modelos tienden a sobrestimar el recurso solar en promedio, subrepresentando la ocurrencia de nubosidad. De la comparación de ambos trabajos se observa que el modelo ECMWF es el que presenta mejor desempeño, lo que es consistente con otras comparaciones internacionales donde se evalúa el desempeño de este modelo ([Mathiesen y Kleissl, 2011](#); [Perez et al., 2013b](#); [Yang et al., 2022a](#); [Wang et al., 2022](#)).

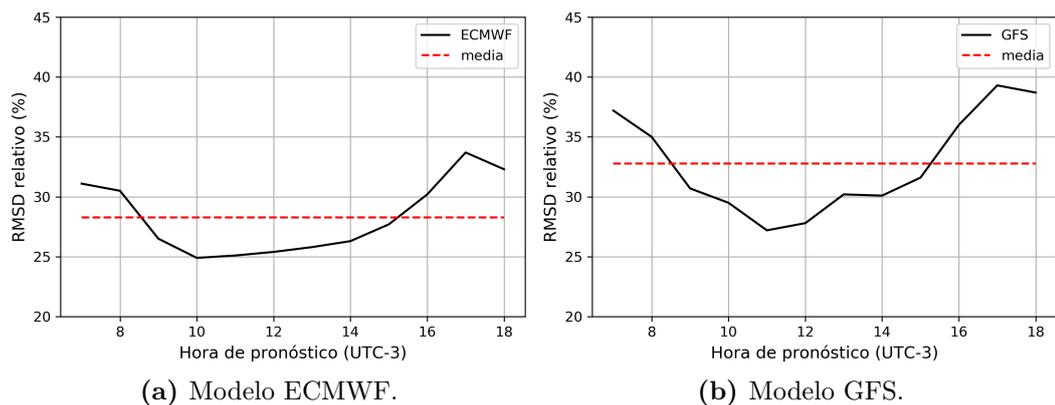


Figura 2.8: Desempeño intra-día modelos numéricos globales ECMWF y GFS para la región Pampa Húmeda. Datos extraídos de [Teixeira-Branco et al. \(2021\)](#) y [Teixeira-Branco et al. \(2022\)](#) para elaborar ambas figuras.

A la hora de comparar métodos de pronóstico por satélite y NWP surge el inconveniente de que sus tasas de actualización son distintas, por lo que no resulta sencillo compararlos. La predicción NWP se actualiza una vez por

día mientras que el pronóstico satelital se puede hacer cada 1 hora, 30 o 10 minutos. Por tanto, un horizonte h para satélite corresponde a una predicción del NWP para un horizonte distinto h^* , y la relación entre ambos depende de en qué hora se haya actualizado la predicción satelital bajo consideración. Lo anterior dificulta la comparación sobre un eje x común. Observando los gráficos de la Figura 2.8, una opción simple es comparar con el promedio de desempeño del NWP a lo largo del día. En este caso, como el ECMWF es el de mejor desempeño, la referencia general sería de $\simeq 28\%$ de RMSD relativo.

En un primer trabajo en la región, en Giacosa y Alonso-Suárez (2020) se implementó y evaluó la técnica de Lorenz et al. para la región de la Pampa Húmeda. Se encontró un RMSD relativo entre 18% y 37% para la predicción satelital entre 1 y 5 horas respectivamente. La comparación entre este trabajo y los trabajos de Teixeira-Branco et al. no es totalmente concluyente, en tanto se utilizaron períodos temporales y procedimientos de control de calidad distintos. No obstante, como se utilizaron los mismos sitios geográficos de medida, permite una comparación preliminar. Esta comparación indica que la predicción satelital con esta técnica simple presentaría un mejor desempeño para las primeras dos horas de pronóstico, en promedio a lo largo del día.

Trabajos internacionales han comparado el desempeño de la predicción por satélite contra la de NWP utilizando mismas estaciones, períodos de tiempo y controles de calidad. Si bien la extrapolación de resultados de desempeño en otros sitios no es directa debido a la dependencia de los resultados con la climatología del sitio, representa una guía general de trabajos donde la comparación entre métodos sí es totalmente concluyente. En Perez y Hoff (2013) se realiza una comparación de desempeño a nivel horario para un año de datos de 8 sitios de Estados Unidos¹ (red de medida SURFRAD, <https://gml.noaa.gov/grad/surfrad/>), con horizontes de pronóstico de 1 a 6 horas. El resultado (Figura 2.9) muestra que el pronóstico con CMV tiene mejor desempeño que el NWP para horizontes de pronóstico de hasta 5 horas. Una conclusión similar se encontró para un año de datos en 274 estaciones piranométricas del Servicio Meteorológico Alemán (Kühnert et al., 2013).

De lo mencionado anteriormente, se observa un mejor desempeño del pronóstico a partir de imágenes satelitales en comparación a los NWP en

¹Aquí el FS se calcula como el cociente del pronóstico y la persistencia (1 es el nivel de referencia). Para las horas 1 a 6 se considera el pronóstico satelital y para 2 días en adelante el pronóstico NWP.

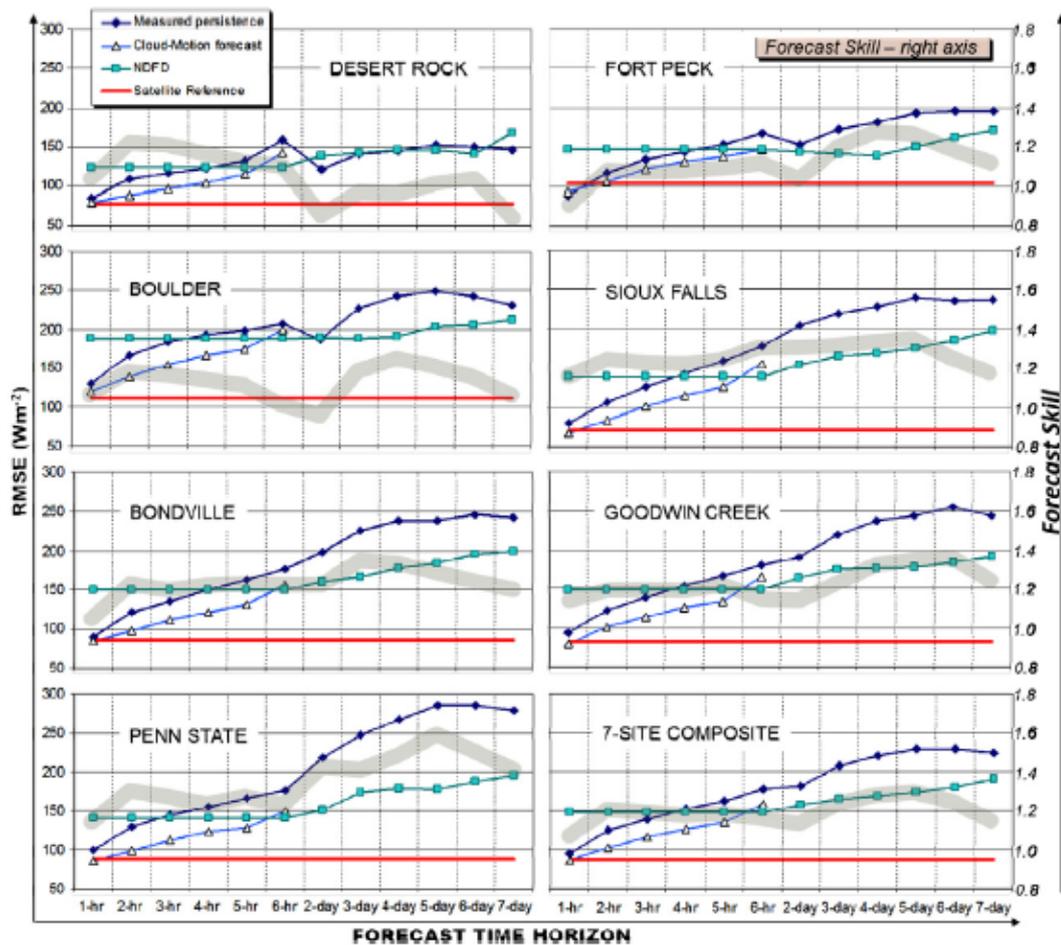


Figura 2.9: Comparación de desempeño intra-día y diario entre pronóstico CMV y NWP (NDFD) en 8 estaciones de Estados Unidos. Imagen extraída de [Perez y Hoff \(2013\)](#).

las primeras horas de pronóstico. Es esperable que el resultado obtenido en Estados Unidos y Europa sobre la transición de desempeño alrededor de los horizontes a 4-5 horas sea cierta también en la Pampa Húmeda, en tanto en ambos trabajos ([Perez y Hoff, 2013](#); [Kühnert et al., 2013](#)) se evalúan sitios de medida con distinto comportamiento de la irradiación solar y climatología. No obstante, y en especial debido a los distintos controles de calidad aplicados, aún no es posible establecer con precisión el horizonte de transición de desempeño regional por comparación de el presente trabajo con los de [Texeira-Branco et al.](#) Sí es posible establecer un ordenamiento de las técnicas satelitales en términos de desempeño, y que se encuentran técnicas de mejor desempeño que el algoritmo de *block-matching* evaluado por [Giacosa y Alonso-Suárez](#) en la región.

Capítulo 3

Datos e implementación

En este capítulo se presentan los datos utilizados en el presente trabajo (medidas en tierra de GHI e imágenes de satélite) y la metodología de implementación de distintos aspectos de la cadena de predicción. Se presentan aquí algunos elementos incrementales o más detallados de la implementación de la predicción. Los métodos a implementar y aspectos relevantes se describieron en la Sección 2.1.

3.1. Datos

Los datos utilizados se pueden separar en dos conjuntos: imágenes satelitales y mediciones terrestres. Las imágenes satelitales fueron capturadas por el satélite geostacionario *GOES-East* que es administrado por la NOAA (National Oceanic and Atmospheric Administration) y genera imágenes que contienen todo el continente americano, incluyendo nuestra región. Las mediciones terrestres fueron adquiridas en distintas estaciones (red de medidas, Sección 3.1.2) ubicadas dentro del territorio de nuestro país. Las imágenes satelitales son utilizadas para elaborar la predicción de irradiación solar en cualquier punto de la región y las medidas terrestres se utilizan solo para evaluar los resultados. Los procedimientos de optimización se realizan sólo a nivel de imagen, sin utilizar las medidas en tierra. A tales efectos las imágenes se dividen en un conjunto de entrenamiento y otro de evaluación, que corresponden respectivamente a los años 2017 y 2016.

Uruguay está contenido en una región climáticamente aún mucho más amplia, conocida como la Pampa Húmeda sudamericana. Esta región está clasi-

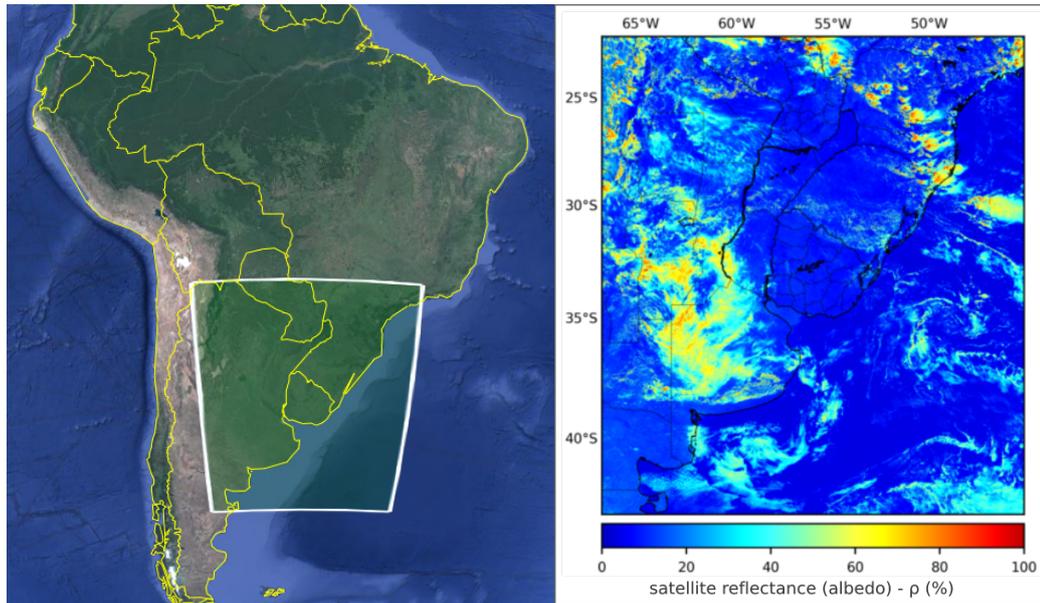
ficada como Cfa (cálido, templado y húmedo, con veranos calurosos) según la clasificación climática actualizada de Köppen-Geiger [Peel et al. \(2007\)](#). Esta es una región subtropical donde se desarrollan complejos sistemas convectivos que tienden a tener picos de desarrollo en horas diurnas [Salio et al. \(2007\)](#), produciendo patrones complejos de nubosidad que afectan directamente la disponibilidad de recurso solar. Los resultados que se obtienen a nivel de imagen son generados para toda la región. Los resultados a nivel de GHI se evalúan en los sitios de medida en Uruguay, pero al ser una región de clima relativamente homogéneo, pueden ser considerados representativos para la Pampa Húmeda.

3.1.1. Imágenes satelitales

Se utilizan imágenes del satélite *GOES-East* en el período 2016-2017. De la información espectral que se obtiene en los distintos canales del *GOES-East*, se considera en el presente trabajo sólo el canal visible. Esta información es convertida en una imagen de albedo (reflectancia planetaria, ρ_p) con procedimientos estándar ([Alonso-Suárez, 2017](#)). Las nubes son más reflectivas que el fondo (suelo, ríos, océanos, etc.) ya que son el elemento en la escena que refleja más irradiación solar al espacio exterior. Esto es cierto en la región de la Pampa Húmeda, donde no hay ocurrencia de nieve o salares.

La región espacial utilizada es la mostrada en la Figura [3.1](#) y contiene completamente a Uruguay, parte de Argentina, Paraguay y el sur de Brasil. La figura ilustra también una imagen típica de albedo, donde la nubosidad es distinguible del fondo. Durante los años 2016 y 2017 el satélite operativo fue el GOES-13. Estas imágenes están ya procesadas en las base de imágenes de LES con las calibraciones recomendadas por la NOAA ([Wu y Sun, 2005](#)). Este satélite adquiere dos imágenes por hora en régimen típico para sudamérica con una resolución nominal de 1 km. La locación del satélite en la órbita geostacionaria es 75° Oeste. La ubicación del satélite resulta en que el tamaño de píxel es variable entre $\simeq 1$ -2 km dentro de la región considerada. La imagen original es proyectada en una grilla regular de $0.015^\circ \times 0.015^\circ$ en latitud-longitud con un proceso de promediado de píxeles. El resultado es una imagen de $1397 \text{ px} \times 1467 \text{ px}$.

Dentro del universo de imágenes del período 2016-2017, se realizó un chequeo con el fin de detectar automáticamente imágenes incompletas o con medidas incoherentes. Para cada imagen se buscó la cantidad de píxeles sin brillo



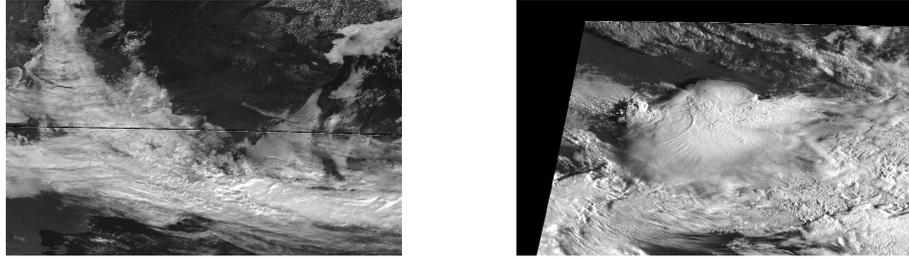
(a) Ubicación de ventana de satélite.

(b) Ejemplo de imagen de albedo.

Figura 3.1: Ubicación y ejemplo de las imágenes obtenidas del *GOES-East*.

en horas diurnas, lo que representa huecos en las imágenes por falla de la adquisición satelital. Estos huecos usualmente aparecen en forma de sectores o tiras en la imagen. Si bien son eventos infrecuentes, son posibles, y deben detectarse para no utilizar imágenes corruptas. Si el conteo supera los 100 píxeles (definido por inspección visual de las imágenes con sectores dañados), entonces esa imagen se descarta. En caso de ser menos de 100 píxeles, se realiza un rellanado iterativo utilizando el promedio de los 4 vecinos más cercanos. Como ejemplo, en la Figura 3.2 se muestran dos imágenes descartadas por el automatismo. Se puede observar que la cantidad de 100 píxeles es un número bajo en comparación a la cantidad de píxeles en la imagen (es menor al 0.01 % de la imagen), por lo que este criterio es conservador. Este proceso se ejecuta sobre el total de imágenes disponibles (15288 del año 2016 y 14856 del año 2017). Se eliminaron 15 imágenes del año 2016 y 20 imágenes del año 2017, y se interpolaron 88 imágenes del año 2016 y 151 del año 2017.

Como los píxeles en la interfaz noche/día de una imagen no contienen un borde muy marcado, el criterio para definir “amanecer” y “atardecer” es que el Sol ya se encuentre francamente por encima de horizonte, utilizando una altura solar (α_s) mínima de 5.7° (o, su equivalente, coseno del ángulo cenital mayor a 0.1). En la región de la imagen donde se cumple $0 < \alpha_s < 5.7^\circ$ (Sol muy bajo al amanecer o atardecer) la medida del satélite es un valor pequeño,



(a) banda horizontal al centro faltante (b) banda horizontal superior faltante

Figura 3.2: Imágenes descartadas por píxeles faltantes.

lo que resulta en valores de albedo satelital de alta incertidumbre, y en general son descartados o tratados en forma diferencial. Debido a lo anterior, se tienen en cuenta sólo las imágenes en los que la región de Uruguay, acotada por Latitud $\in [-36^\circ, -29^\circ]$ y Longitud $\in [-60^\circ, -52^\circ]$, tengan todos sus píxeles en franco día, con el criterio de $\alpha_s > 5.7^\circ$. Se consideró esta región para asegurar información de las primeras horas del día sobre Uruguay. Esta región puede observarse en la Figura 3.3 con un rectángulo de bordes punteados en rojo. De esta forma se intenta evitar que se generen predicciones sobre Uruguay con información muy ruidosa de los primeros puntos del día.

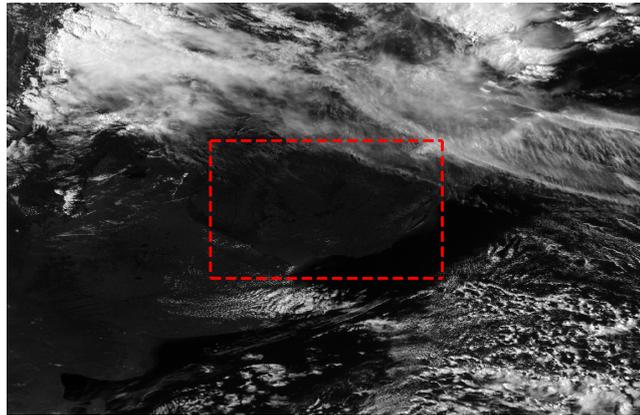


Figura 3.3: Región de control.

Finalmente, se consideran solo el conjunto de imágenes que están separadas 30 minutos (por lo general, en cada hora se tienen dos imágenes: una en el minuto 8 y otro en el minuto 38). También, cada 3 horas, hay imágenes adquiridas en el minuto 45 de la hora, que se descartaron por no respetar el paso 30-minutal del soporte temporal. Cabe comentar que existen algunos faltantes de imágenes debido a mantenimientos del satélite y a imágenes descartadas.

En este proceso se eliminan imágenes defectuosas, se reparan algunas, y se descartan las imágenes de la noche y de parte del amanecer y atardecer. El resultado final son 6394 imágenes correspondientes al año 2016 y 6329 imágenes correspondientes al año 2017. En Tabla 3.1 y Tabla 3.2 se puede observar la distribución de las imágenes respecto a la hora del día y el mes para el año 2016 y 2017 respectivamente. De estos dos conjuntos de datos, el correspondiente al año 2016 es el que se utiliza para evaluar el resultado de los algoritmos y el de 2017 para el entrenamiento.

hora	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Set	Oct	Nov	Dic	Tot
6	17	0	0	0	0	0	0	0	0	7	29	31	84
7	51	58	49	27	15	0	0	16	40	49	55	62	422
8	51	58	56	56	61	51	54	55	48	50	55	62	657
9	25	29	29	29	31	30	30	30	30	31	29	31	354
10	49	54	53	55	57	50	56	55	47	50	57	62	645
11	49	55	52	54	56	51	56	53	47	50	57	62	642
12	25	28	29	29	31	30	30	31	30	31	30	31	355
13	24	25	22	23	23	19	25	22	15	19	26	31	274
14	45	51	43	49	48	41	50	51	44	47	49	57	575
15	24	28	29	29	31	30	29	31	30	31	28	31	351
16	47	54	47	50	46	40	47	52	46	50	56	62	597
17	47	54	47	47	46	40	46	54	47	50	56	62	596
18	24	29	29	27	31	30	29	31	30	31	29	31	351
19	46	54	40	15	0	0	0	8	29	49	56	61	358
20	43	26	0	0	0	0	0	0	0	0	18	46	133
Tot	567	603	525	490	476	412	452	489	483	545	630	722	6394

Tabla 3.1: Distribución de imágenes disponibles en horas del día (hora en el centro del intervalo) y meses del año 2016.

hora	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Set	Oct	Nov	Dic	Tot
6	21	0	0	0	0	0	0	0	0	0	29	31	81
7	61	55	51	20	13	0	0	16	43	36	56	60	411
8	61	54	56	49	58	53	60	56	52	36	56	59	650
9	31	28	30	29	31	30	30	31	29	18	28	31	346
10	60	51	59	52	56	56	59	58	53	35	55	61	655
11	57	52	56	52	55	55	59	57	53	37	56	62	651
12	29	27	30	30	31	29	29	30	29	19	28	30	341
13	26	21	27	19	22	22	26	25	24	18	28	31	289
14	51	45	43	48	47	45	48	51	46	33	51	54	562
15	29	28	30	29	31	30	31	31	29	19	27	31	345
16	54	47	48	45	46	45	50	51	50	34	56	60	586
17	56	45	49	44	44	43	49	50	51	34	57	60	582
18	30	27	31	29	31	30	30	30	30	19	29	30	346
19	56	47	39	16	0	0	0	9	30	25	57	60	339
20	53	27	1	0	0	0	0	0	0	0	18	46	145
Tot	675	554	550	462	465	438	471	495	519	363	631	706	6329

Tabla 3.2: Distribución de imágenes disponibles en horas del día (hora en el centro del intervalo) y meses del año 2017.

3.1.2. Medidas en tierra

Se utilizaron los datos de seis estaciones de medidas de GHI en zonas rurales y semi-rurales del territorio uruguayo (Figura 3.4). Estas forman parte de la red de medidas del Laboratorio de Energía Solar (LES, <http://les.edu.uy/>). Los metadatos de estas estaciones se presentan en la Tabla 3.3.

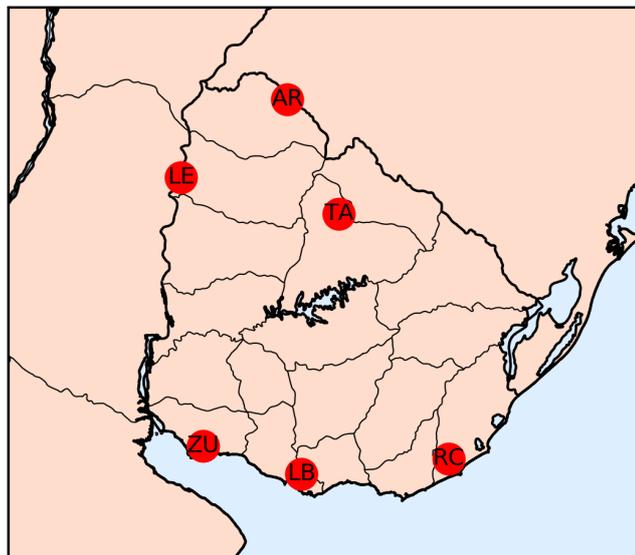


Figura 3.4: Ubicación de las estaciones terrestres.

En todas las estaciones se utilizan piranómetros de termopila de respuesta espectral plana y Clase A según la norma ISO 9060:2018. La estación LE está

nombre estación	código estación	latitud (deg)	longitud (deg)	altitud (m)	$\overline{G_h}$ (Wh/m ²)
Salto	LE	-31.28	-57.92	60	411.7
Rocha	RC	-34.49	-54.32	30	394.6
Las Brujas	LB	-34.67	-56.34	37	398.2
La Estanzuela	ZU	-34.34	-57.69	70	405.6
Tacuarembó	TA	-31.71	-55.83	142	402.7
Artigas	AR	-30.40	-56.51	121	423.3

Tabla 3.3: Nombre, código, y ubicación de las estaciones de medida y promedio de irradiación GHI horaria.

dentro del predio experimental del LES en Salto y recibe mantenimiento diario de limpieza de cúpulas y verificación. El resto de las estaciones están ubicadas en predios del INIA o INUMET, dentro del campo de sensores meteorológicos de estas instituciones. El mantenimiento de limpieza en estas estaciones se realiza en base mensual por el personal de la estación y en base anual o bienal por el LES. En todas las estaciones los piranómetros son calibrados al menos con frecuencia bienal (cada dos años), como indican las buenas prácticas de medición de la irradiación solar [Abal et al. \(2018\)](#). La calibración se realiza en el LES contra un Estándar Secundario que el laboratorio mantiene con trazabilidad técnica al Patrón Primario mundial (WRR, *World Radiation Reference*) del *World Radiation Center* (WRC) en Davos, Suiza. Las estaciones cuentan con adquisidores profesionales y conectividad remota, enviando los datos registrados a escala minutal al final de cada día. El valor minutal registrado se construye como promedio de 6 medidas instantáneas. Se asigna una incertidumbre P95 de 3% en la medida de GHI para la estación LE y de 5% para el resto. Cabe destacar que las incertidumbres son significativamente menores que las incertidumbres de pronóstico.

Las medidas de GHI con cadencia de 1 minuto son analizadas para determinar datos erróneos, utilizando los límites BSRN [McArthur \(2005\)](#) que encuentran datos atípicos y datos imposibles. Luego de este proceso, los datos son integrados de forma horaria utilizando la etiqueta temporal del satélite como soporte temporal. Es decir, para cada etiqueta temporal se computan los valores horarios de 1 a 5 horas hacia adelante. Sólo se consideraron datos con altitud solar $> 7^\circ$ (coseno del ángulo cenital > 0.1). En la [Tabla 3.3](#) se

muestra también el promedio de irradiación solar horaria promedio para cada estación. Este promedio se utiliza para la normalización de métricas de desempeño. En el presente trabajo las medidas de GHI se requieren solo para la etapa de evaluación del pronóstico a nivel de irradiación, por lo que se consideran sólo correspondientes al año 2016.

3.2. Pronóstico de las próximas imágenes

En esta sección se presenta como se realiza el pronóstico de las siguientes imágenes en la secuencia a partir del CMV calculado entre dos imágenes consecutivas. Esto representa una extrapolación del movimiento hacia el futuro. El cálculo del CMV para cada técnica se realiza a través del algoritmo de *block-matching* o la resolución de los problemas de optimización de la Sección 2.1.

Se define el horizonte de pronóstico como el tiempo a futuro en el que se quiere pronosticar. Dado el paso entre las imágenes consecutivas Δt y considerándolo parte del soporte temporal, se define el parámetro k que establece la cantidad de pasos Δt para llegar al horizonte deseado. Llamamos futuro a todos los horizontes con k positivo, pasado a los horizontes con k negativo y presente o momento actual a los horizontes con $k = 0$. Por lo tanto, una imagen en la posición k de la secuencia será representada como I_k . Se consideran los horizontes de pronóstico horarios, es decir, los valores de k pares ($\Delta t = 30$ minutos). La elección de estos horizontes se basa en que el modelo utilizado para estimar la irradiación solar a partir de las imágenes ha sido ajustado a la irradiación horaria y se cuenta con una evaluación detallada de la incertidumbre de esta estimación en la región (Laguarda et al., 2020; Alonso-Suárez, 2017), que utilizan imágenes de la misma generación de *GOES-East* que en este trabajo. Estas evaluaciones proporcionan un nivel de incertidumbre de referencia para el presente trabajo y también herramientas ajustadas para la conversión de la imagen satelital a irradiación por hora.

Para realizar el pronóstico se asume que la distribución espacial del CMV no cambia con el tiempo. El CMV, a priori, es el que se calcula entre I_{-1} (imagen tomada un tiempo Δt antes) y I_0 (imagen actual). Realizado de esta manera, el CMV tiene como origen I_{-1} y apunta hacia I_0 , y se requiere con origen en I_0 , ya que el pronóstico se realiza partiendo de I_0 . Una forma de obtener el CMV con origen en I_0 es calcularlo considerando I_0 como imagen origen y I_{-1} como imagen destino, y luego sólo es necesario cambiar el sentido

del CMV de modo que apunte hacia el futuro.

Se presentan dos alternativas para la extrapolación del movimiento, que pueden verse en la Figura 3.5:

- Se calculan las imágenes futuras en forma iterativa, generando imágenes intermedias con paso Δt hasta llegar al horizonte deseado, partiendo de la imagen I_0 . Cada imagen intermedia pasa a ser la nueva imagen origen, donde se aplica el procedimiento de la Ec. 3.1 utilizando el mismo CMV calculado al inicio.
- Se calcula directamente el pronóstico para un horizonte dado escalando el CMV por el multiplicador correspondiente. Para un horizonte dado k , la imagen futura se calcula directamente como en la Ec. 3.2.

$$I_k(x, y) = I_{k-1}(x + u, y + v) \quad (3.1)$$

$$I_k(x, y) = I_0(x + k \times u, y + k \times v) \quad (3.2)$$

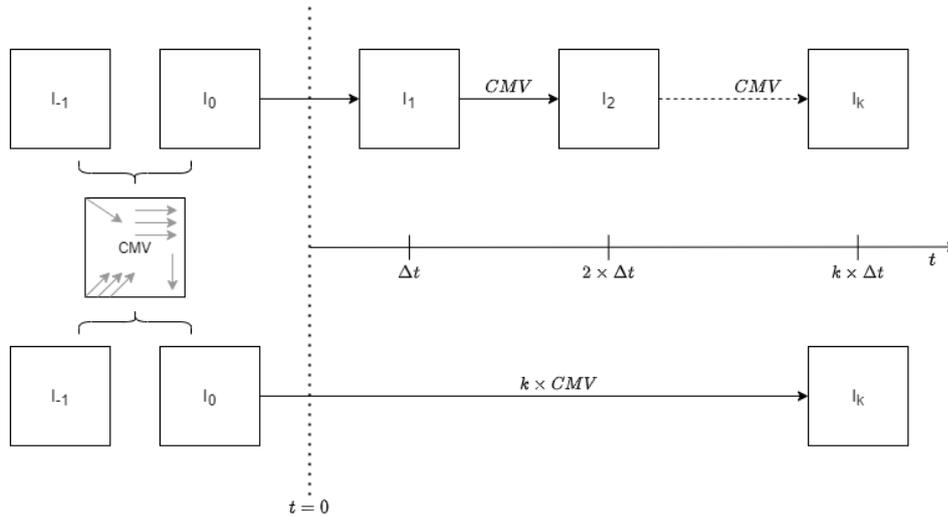


Figura 3.5: Alternativas para pronosticar I_k . Se considera el tiempo actual como cero para mejorar la visualización.

La primer opción introduce menores desplazamientos en cada etapa y esto hace que se siga mejor la trayectoria dada por el CMV estático. Como contra se puede mencionar que de llegar a un pixel con desplazamiento asociado igual a cero, implica que ese pixel ya no se mueve a futuro. Esto puede traer aparejado una acumulación de nubosidad en ciertas regiones donde el CMV es cero. En

los casos de campos suaves, la segunda alternativa puede ser la más adecuada. De la observación, surge que los CMV son bastante caóticos por lo que la primera opción parece la más adecuada. Notar que no se recalcula el CMV en cada paso sino que se utiliza el original en todos los pasos. Esto es, un CMV constante en el pronóstico, pero que a priori es distinto en cada píxel, por lo que el resultado es distinto a multiplicar por k el CMV.

3.2.1. Estrategias para construir la imagen destino

En este caso, por imagen destino, hablamos de construir la siguiente imagen de la secuencia (I_k) conociendo la imagen anterior (I_{k-1}) y el CMV ya estimado originalmente entre las imágenes I_{-1} y I_0 . Se seleccionaron 3 alternativas para este procedimiento, abordando en forma diferente la extrapolación de una imagen, que se denominan: OW, DN y DL.

En OW¹ se divide la imagen origen en bloques o ventanas de $W \times W$ sin superposición (Figura 3.6). La elección de W es tal que se minimice el error cuadrático medio entre la imagen estimada y la real. Se estima donde debería ubicarse ese bloque en la imagen destino considerando el vector CMV aplicado al centro del bloque y con sentido y módulo equivalente al promedio del CMV de los píxeles de ese bloque. El resultado, Figura 3.6, puede contener bloques que se superponen, bloques que quedan parcial o totalmente afuera de la imagen y espacios donde no se asigna ningún valor. Para el caso de superposición, se optó por asignar el promedio asociado a los píxeles superpuestos. Para los píxeles que no tienen un valor asignado luego de que se colocan todos los bloques en la imagen destino, se realiza un proceso de relleno (*inpainting*) en la imagen con la función `inpaint` de OpenCV. Este método decide el valor de cada píxel basándose en la información de su entorno, en este caso por una circunferencia de radio 3 (píxeles) con centro en el píxel en cuestión, y utiliza un algoritmo basado en las ecuaciones de dinámica de fluidos de Navier-Stokes.

DN y DL, al contrario de OW, recorren la imagen destino píxel a píxel y le asignan a cada uno un valor calculado en base a los datos de la imagen de origen. La diferencia entre estas estrategias está en cómo calculan este valor. La Ec. 3.3 muestra cómo se calcula la nueva imagen en base los datos conocidos.

$$I_k(x, y) = I_{k-1}(x - u, y - v) \quad (3.3)$$

¹esta estrategia se probó ya que no había argumentos a favor o en contra en la literatura.

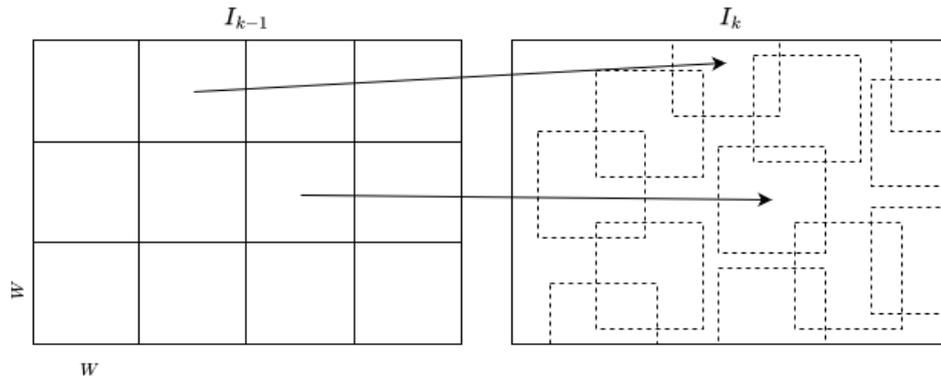


Figura 3.6: Estrategia OW para el completado de imagen destino. La imagen destino se conforma con los bloques de la imagen origen trasladados según el CMV promedio de cada uno.

En la Figura 3.7 se muestra el procedimiento para obtener el valor de cada píxel de la imagen destino. Se recorre la imagen destino píxel a píxel y en cada píxel (x, y) se mira su correspondiente en la imagen origen aplicando el campo CMV con sentido opuesto. Esto es, se busca en la imagen origen el píxel o los píxeles cercanos a $((x - u(x, y), y - v(x, y)))$. Si hubiera un píxel determinado en la imagen origen, éste se asigna a la imagen destino, pero sucede que este procedimiento, en la mayoría de los casos, no da exacta la posición de un píxel dado que el campo (u, v) no necesariamente es entero, y es en estos casos donde se necesita estimar el valor a asignar. Observar que la posición $((x - u(x, y), y - v(x, y)))$ siempre va a estar entre 4 píxeles vecinos. El método DN asigna el valor del píxel más cercano y DL asigna la interpolación bilineal que considera los valores de los 4 vecinos y su peso de acuerdo a la distancia respecto al punto que se quiere calcular. Observar que este método va a tener, en la mayoría de los casos, un valor para cada píxel destino. Los casos donde no hay correspondencia con la imagen origen se dan en los bordes, y corresponden a lugares que quedan fuera de los límites de la imagen origen. Esto conlleva a problemas de borde conocidos para la técnica. Un detalle a tener en cuenta es que todo objeto que aparezca o desaparezca en el futuro, no se puede predecir mediante este tipo de métodos CMV.

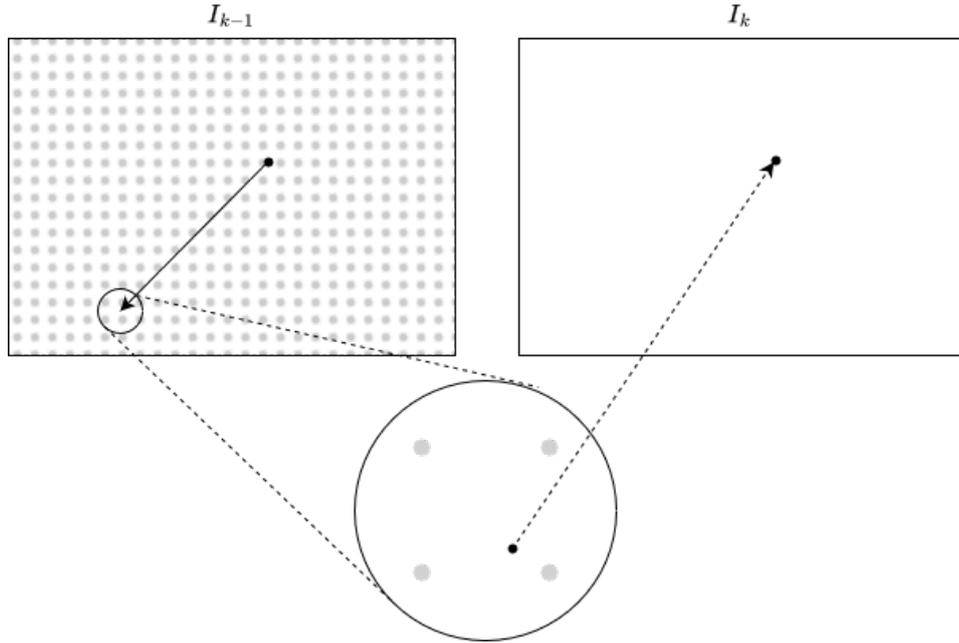


Figura 3.7: Estrategias DN y DL para el completado de imagen destino. El valor de la imagen destino en el píxel (x, y) , $I_k(x, y)$, se calcula con el valor del píxel que al aplicarle el CMV nos lleva a (x, y) .

3.3. Optimización de parámetros

Cada uno de los métodos detallados en la Sección 2.1 tienen parámetros a optimizar. No es intención optimizar los algoritmos, si no optimizar los parámetros más relevantes de cada método. Las implementaciones computacionales de los métodos tienen parámetros propios. Optimizarlos todos ellos sería una tarea inabarcable y de alto costo computacional. En la elección se priorizaron los parámetros propios de la formulación de cada método y aquellos que, según la experiencia en el problema específico, afectan más al cálculo del CMV. Se priorizó también que los parámetros a optimizar tengan coherencia entre los modelos, es decir, que tengan interpretaciones similares. Con estas consideraciones, los parámetros seleccionados para optimizar en cada método se presentan en la Tabla 3.4.

LK-avg	LK-afn	FRB	HS	TVL1	PIV
w (px)	w (px)	w (px)	α	λ	w_n (px)
M	M	M	M	M	w_s (px)

Tabla 3.4: Parámetros a optimizar en cada método.

Para la optimización de los parámetros se seleccionan dos imágenes consecutivas en el soporte temporal de 30 minutos y se realiza la predicción de la siguiente imagen en el soporte temporal, en base a la estimación del CMV con las dos primeras. Esto es, se estima $I(x, y, t + 1)$ a partir de la imagen $I(x, y, t)$ y un CMV estimado de las imágenes $I(x, y, t)$ e $I(x, y, t - 1)$. A la imagen predicha se la compara con la original midiendo el desvío cuadrático medio (RMSD). Los conjuntos de 3 imágenes consecutivas proveen entonces un conjunto auto-supervisado para la optimización de parámetros en la estimación del CMV. El procedimiento tiene implícito la utilización de un método de extrapolación de la próxima imagen a partir del CMV y la imagen a tiempo t . Para la optimización se utilizó el método más estándar de extrapolación, la búsqueda hacia atrás donde la imagen $I(x, y, t + 1)$ se construye como $I(x - u, y - v, t)$ utilizando interpolación bilineal (DL, Sección 3.2.1). Para cada método, se definen rangos en los que pueden variar los parámetros a optimizar y se evalúa el promedio de RMSD en el conjunto de ternas de imágenes del conjunto de entrenamiento. Este conjunto está compuesto de imágenes de satélite del año 2017. La separación de las imágenes en conjuntos de entrenamiento y validación se presenta en la Sección 3.1. Los parámetros óptimos son los que minimizan el promedio de RMSD a nivel de imagen.

3.4. Pronóstico de GHI

En lo analizado hasta ahora, se pueden pronosticar imágenes futuras, esto es, el nivel de brillo de cada píxel en el futuro (albedo). Lo que está faltando es poder traducir las imágenes pronosticadas en un valor de irradiación solar horaria sobre plano horizontal (GHI) confiable. El presente trabajo utiliza un método CIM (*Cloud Index Method*).

Los métodos CIM utilizan un modelo de cielo claro para estimar la irradiación en condiciones de cielo claro (GHI_{CSK}) y ésta se atenúa de acuerdo a la nubosidad presente en la imagen (función del brillo en la imagen). La forma de hacer esto se muestra en la Ec. 3.4 donde GHI a estimar es el producto de GHI_{CSK} por una función del índice de nubosidad satelital, C , que cumple el objetivo de atenuar la irradiación de cielo claro.

$$GHI = GHI_{CSK} \times F(C) \quad (3.4)$$

C cuantifica el nivel de nubosidad y se define como una cantidad adimensional $C \in [0, 1]$ donde 1 es el nivel con más nubosidad y 0 es la ausencia de nubes. $F(C)$ es la función definida en Ec. 3.5, donde a y b son parámetros que se deben ajustar a una región dada. Si bien estos parámetros tienen poca variación espacial, pueden ser ajustados finamente a cada sitio obteniendo una pequeña mejora de desempeño. En el presente trabajo se eligió esta segunda estrategia, utilizando los coeficientes de cada sitio ajustados en [Laguarda et al. \(2020\)](#). Los valores considerados se muestran en la Tabla 3.5. Se puede ver una relación inversamente proporcional entre $F(C)$ y C . A más nubosidad ($C \rightarrow 1$), $F(C)$ se hace mínimo y con menos nubosidad ($C \rightarrow 0$), $F(C)$ es máximo. Esto concuerda con la Ec. 3.4 ya que, cuando hay más nubosidad, se da una atenuación mayor (a la baja) en GHI (GHI_{CSK} por un factor chico, menor a 1). Todo depende de los valores de a y b obtenidos en el sitio de evaluación $F(C) \in [a, a + b]$, que va en todos los casos de un valor pequeño $a \sim 0$ y un valor $a + b \sim 1$.

$$F(C) = a + b \times (1 - C) \quad (3.5)$$

Estación	a	b
LE	0.040	0.94
LB	0.044	0.93
RC	0.054	0.91
AR	0.048	0.92
ZU	0.045	0.92
TA	0.045	0.93

Tabla 3.5: Valores de a y b considerados por estación ([Laguarda et al., 2020](#)).

El valor de C depende del nivel de brillo de la imagen de albedo (ρ_p) y se obtiene normalizando respecto a valores extremos ($\rho_p \in [\rho_{min}, \rho_{max}]$). Esto se puede ver en la Ec. 3.6. Se establece $C = 1$ para valores que superen esta cantidad y $C = 0$ para valores negativos.

$$C = \frac{\rho_p - \rho_{min}}{\rho_{max} - \rho_{min}} \quad , \quad \rho_{min} < \rho_p < \rho_{max} \quad (3.6)$$

Para calcular ρ_{min} es necesario tener en cuenta el brillo de fondo. El brillo de fondo normalizado respecto a la posición relativa del sol en cada punto, es

lo que se asignará a ρ_{min} . Además se considera $\rho_{max} = 0.80$. El procedimiento de cálculo de ρ_{min} y la estimación ρ_{max} se realiza de acuerdo a [Laguarda et al. \(2020\)](#); [Alonso-Suárez et al. \(2014, 2011\)](#).

3.4.1. CIM-ESRA

Se utiliza el modelo ESRA para la estimación de GHI_{CSK} . Se presenta en esta sección una breve descripción del modelo. Mayores detalles se encuentran en el Apéndice [A](#).

La implementación del modelo se basa en un único parámetro, conocido como Turbidez de Linke (T_L), que engloba todos los fenómenos de atenuación en una atmósfera sin nubes. En Uruguay se cuenta con estudios del régimen típico de la Turbidez de Linke [Laguarda y Abal \(2016\)](#) a escala mensual. En la [Tabla 3.6](#) se muestran estos valores para la zona norte y sur del río Negro. Para tener mayor resolución temporal y no tener discontinuidades apreciables mes a mes, se utilizó el T_L a escala diaria ([Figura 3.8](#)), tanto para norte como para sur, interpolando los valores mensuales considerando que corresponden a la mitad del mes en cuestión.

Mes	Sur	Norte
1	3.037	3.127
2	2.964	3.132
3	2.839	2.977
4	2.659	2.775
5	2.568	2.706
6	2.434	2.554
7	2.450	2.595
8	2.560	2.648
9	2.722	2.852
10	2.792	2.872
11	2.908	2.969
12	2.963	2.998

Tabla 3.6: T_L mensual discriminado por zonas norte y sur.

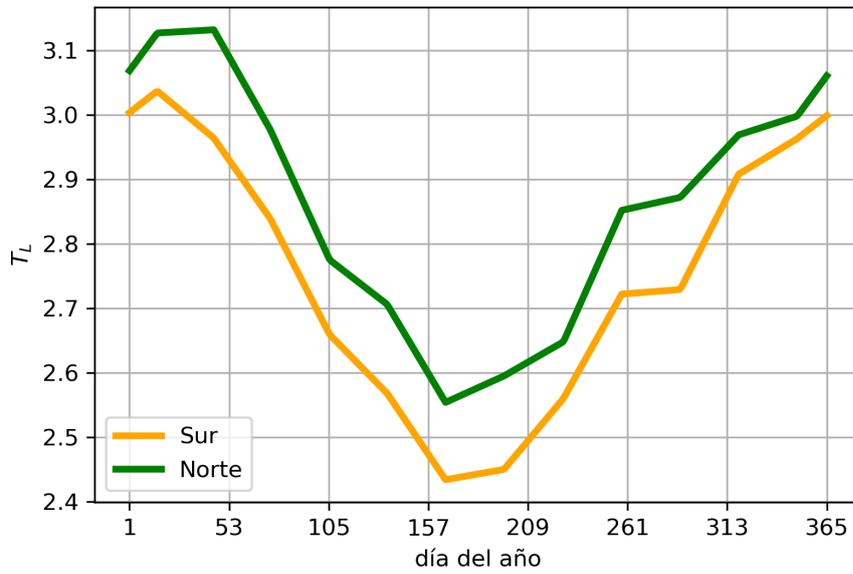


Figura 3.8: T_L diario.

Se modelan las componentes de irradiación directa normal (G_b) y la difusa en plano horizontal (G_d) con este modelo, a partir de las cuáles se calcula la GHI_{CSK} . Los detalles sobre el cálculo de estas componentes a partir de la Turbidez de Linke diaria se detallan en el Apéndice A.

Capítulo 4

Resultados

En este Capítulo se presentan los resultados de optimización de los métodos, la evaluación de desempeño del pronóstico resultante con cada técnica, diferentes estrategias de extrapolación del movimiento, y un análisis general de los resultados.

4.1. Conjuntos de datos

Los datos utilizados en el presente trabajo son los comentados en la Sección 3.1. Los datos se dividen en 3 grandes conjuntos: imágenes satelitales del año 2016, imágenes satelitales del año 2017 y datos de tierra correspondientes al año 2016. Las imágenes satelitales del año 2017 se utilizaron para la optimización de los métodos de estimación del CMV y la ventana óptima de la estrategia OW. Para el cálculo del parámetro $\gamma(h)$ de la persistencia convexa (Sección 2.2.1) se utilizaron los datos de tierra del año 2016. Las imágenes satelitales del año 2016 se utilizaron para la evaluación de desempeño y comparación de métodos. Esta evaluación se realiza a nivel de imágenes (capacidad de predecir píxel a píxel las imágenes futuras) y a nivel de irradiación terrestre (en los sitios donde hay medidas disponibles). Por tanto, los datos de tierra del año 2016 se utilizan también para este fin. El análisis del desempeño permite elegir la mejor estrategia de pronóstico.

4.2. Optimización

Para la optimización de los métodos se utilizaron 600 ternas de imágenes del conjunto de imágenes de 2017 que cumplen estar separadas 30 minutos entre ellas, todos sus píxeles están dentro del día ($\alpha_s > 5.7^\circ$) y tienen albedo positivo, no incluyendo imágenes con sectores corrompidos. Para cada método y combinación de parámetros, se usan las ternas de imágenes del conjunto de entrenamiento para calcular el CMV entre las dos primeras imágenes y, partiendo de la segunda, se pronostica la tercera. Este pronóstico es de $\Delta t = 30$ minutos al futuro. De esta forma se puede comparar la imagen pronosticada con la original. La combinación de parámetros óptima es aquella que minimiza el RMSD promedio en las 600 ternas (se calcula el RMSD para cada imagen pronosticada, y luego se promedia en las imágenes). Para evitar posibles artificios que puedan generarse por efectos de borde, se quita un pequeño marco de ancho 50 px para realizar la comparación. El método de extrapolación utilizado es el DL, dado que es el más estándar de los tres a analizar. Los parámetros a optimizar se identificaron en la Sección 3.3 y los resultados obtenidos se muestran en la Tabla 4.1.

LK-avg		LK-afn		FRB		HS		TVL1		PIV	
w	50 px	w	60 px	w	22 px	α	0.800	λ	0.055	w_n	120 px
M	3	M	4	M	5	M	5	M	6	w_s	144 px

Tabla 4.1: Parámetros óptimos para cada método de estimación del CMV.

En la Figura 4.1 se puede ver el detalle de la optimización para cada método, con gráficos de RMSD relativo en función de los parámetros seleccionados para cada método. Se señala también la combinación de parámetros que lleva al mínimo buscado. Variaciones pequeñas de los valores óptimos de los parámetros α , λ , w y w_n no parecen afectar en gran medida el RMSD relativo. El factor de submuestreo o cantidad de niveles M afecta al RMSD relativo en menos de 1% en valores próximos al valor óptimo ($M^{\text{opt}} \pm 1$). También se observa que a partir de $M = 4$ (estructura piramidal de hasta 4 pisos), es suficiente para tener un valor próximo al óptimo con menos costo computacional. En todos los casos se consideró el valor óptimo por más que la ganancia sea marginal ($M = 5$ es un valor adecuado para la mayoría de los métodos). En los métodos HS y TVL1, los valores de α y λ indican que la solución proporciona menor peso al término de ajuste a datos (restricción de brillo constante del

OF) que al término que impone regularidad del campo de desplazamientos¹, lo que conduce a CMV suavizados como mejor aproximación.

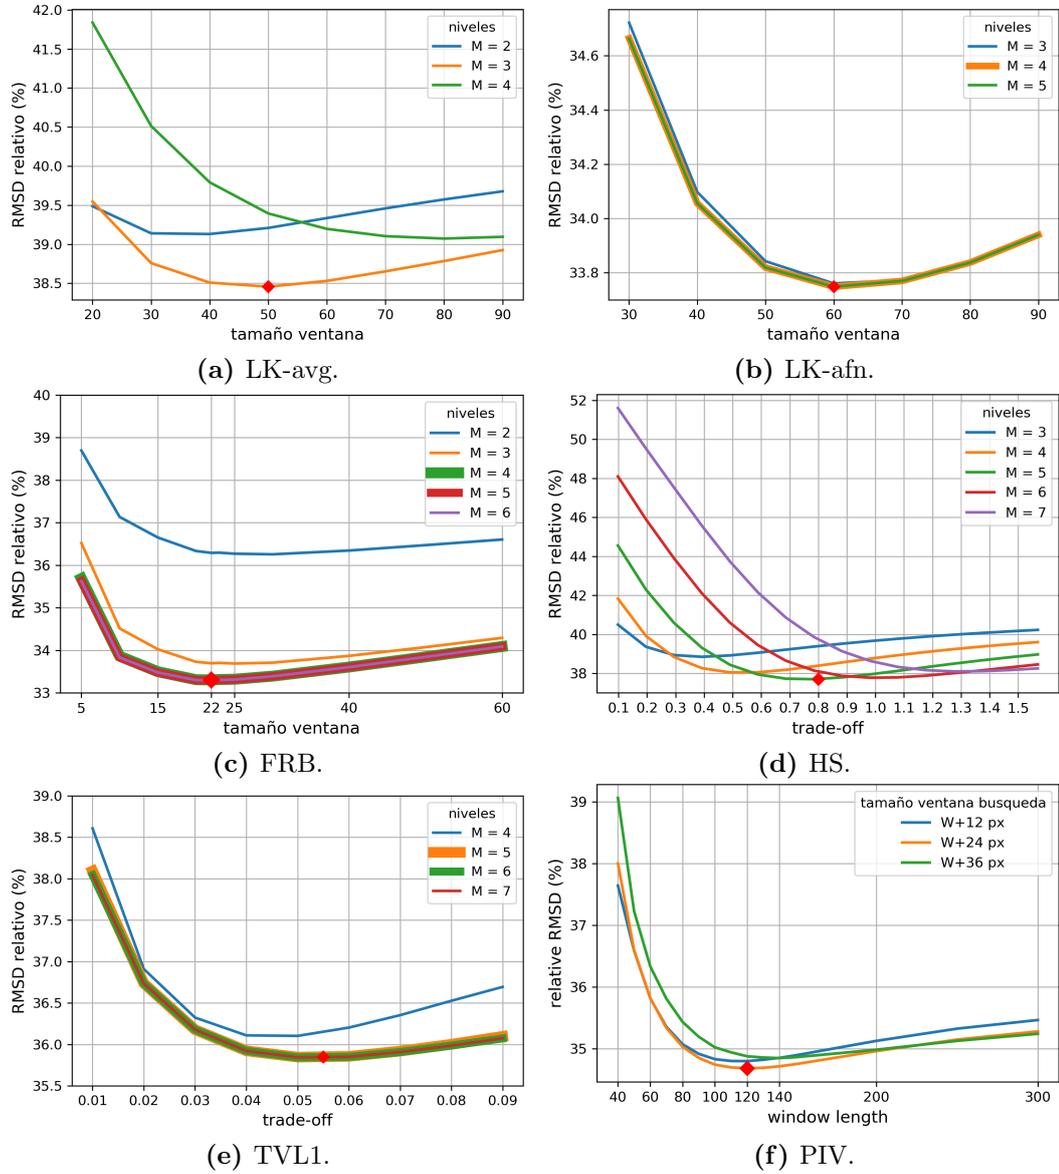


Figura 4.1: Detalle de variación de RMSD relativo respecto a los parámetros seleccionados para cada método y su correspondiente mínimo.

Se debe notar que los resultados cuantitativos que surgen de los gráficos no son representativos del desempeño de predicción, ya que son sobre el conjunto de entrenamiento. Estos gráficos buscan ser de utilidad para visualizar que esos mínimos existen y mostrar cómo pueden variar los resultados al variar

¹Notar que los parámetros de *trade-off* α y λ de los métodos HS y TVL1 respectivamente, tienen la interpretación opuesta.

los parámetros. Los valores obtenidos y mostrados en la Tabla 4.1 son los que se usan para medir el desempeño de los métodos sobre el conjunto de evaluación. La optimización realizada aquí, en rigor, es para el pronóstico de la próxima imagen. Se tomó esta decisión debido a que la construcción de próximas imágenes es iterativa, y se ejecuta para un paso Δt en cada etapa, y en el entendido de que una mejor predicción de la imagen se traslada directamente a una mejor predicción de irradiación solar. La optimización de parámetros dependiendo del horizonte de pronóstico o para el objetivo de irradiación solar, que podría resultar en parámetros un poco distintos, está por fuera del alcance de esta tesis.

4.3. Estrategias de extrapolación

Esta sección corresponde a la técnica utilizada para generar la imagen pronosticada a partir de la última imagen y el CMV estimado. De las tres técnicas inspeccionadas (OW, DN, y DL, Sección 3.2.1), la OW es la única que requiere optimizar un parámetro. Dicho parámetro es el tamaño de la ventana que se traslada desde la imagen origen a la destino a la velocidad promedio de los píxeles que la componen. En el caso de OW, la ventana óptima seleccionada fue de 20×20 px en un compromiso entre el RMSD relativo obtenido (en el pronóstico de la siguiente imagen), que disminuye al achicar el tamaño de la ventana, y el tiempo de ejecución promedio, que crece significativamente al achicar el tamaño de la ventana. La variación de estas cantidades respecto a este parámetro se muestran en la Figura 4.2 utilizando el CMV del método TVL1 (notar que el eje y del gráfico de tiempo está en escala logarítmica). El conjunto de imágenes para determinar la ventana óptima corresponde al año 2017, dado que es un entrenamiento. Una vez optimizada, esta ventana del método OW se mantiene para todos los horizontes de pronóstico, cuyas imágenes pronosticadas se generan iterativamente (al igual que en las otras estrategias de extrapolación).

Utilizando los parámetros óptimos obtenidos y el conjunto de imágenes de 2016, se realiza el pronóstico con horizonte de pronóstico por hora de 1 a 5 horas para cada estrategia de pronóstico (Sección 3.2.1). En la Figura 4.3 se pueden observar los RMSD relativos para cada método asociado a las distintas estrategias empleadas para la construcción de la imagen pronosticada (extrapolación). También se agrega como referencia la persistencia a nivel de imagen

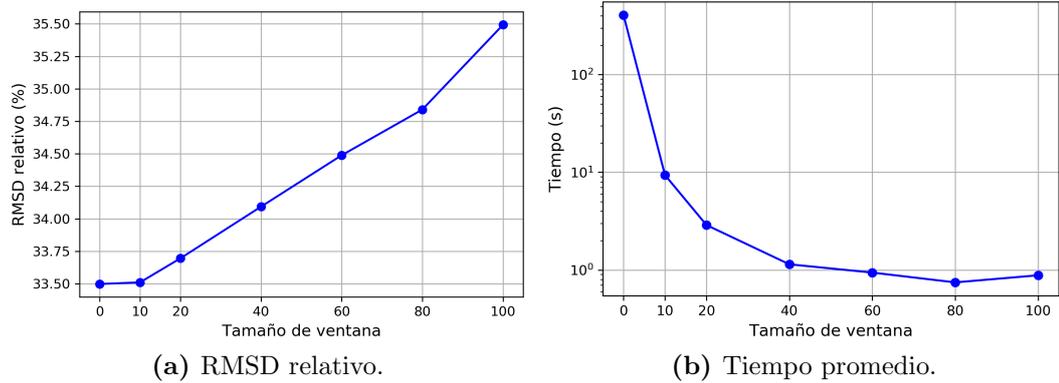


Figura 4.2: Evaluación de estrategia OW para diferentes tamaños de ventana. Indicadores relativos respecto a la media de albedo de las imágenes de $\bar{\rho}_p = 0.28$.

(Sección 2.2.1.1). En todos los métodos el RMSD relativo es menor que la persistencia para todos los horizontes de pronóstico. Se observa que el método DL es el que produce mejores resultados en todos los casos, seguido por el DN y finalmente el OW. Para todos los métodos, si bien los resultados son similares, la estrategia DL es la seleccionada, tanto por el resultado como por su simpleza, y es la que se utiliza en lo que sigue para construir las imágenes pronosticadas.

4.4. Evaluación a nivel de imagen

El desempeño del pronóstico a nivel de imagen se realiza comparando píxel a píxel la imagen de albedo pronosticado en cada horizonte de pronóstico con la imagen real. El conjunto de imágenes utilizado es el conjunto correspondiente al año 2016. En la Tabla 4.2 y Figura 4.4 se presentan las métricas de desempeño en función del horizonte de pronóstico para cada método con los parámetros óptimos y de la persistencia a nivel de imagen. Para todos los métodos se logra mejor desempeño en RMSD relativo que la persistencia en todos los horizontes de pronóstico. Observando el FS, a medida que aumenta el horizonte de pronóstico, el desempeño en RMSD relativo de los métodos empeora. En cuanto al MBD relativo, hay una tendencia a sobrestimar el albedo a menores horizontes de pronóstico y a subestimar a medida que el horizonte de pronóstico aumenta.

TVL1 y LK-afn son los que tienen mejor desempeño en RMSD relativo y esto se mantiene en los distintos horizontes de pronóstico. La mayor diferencia

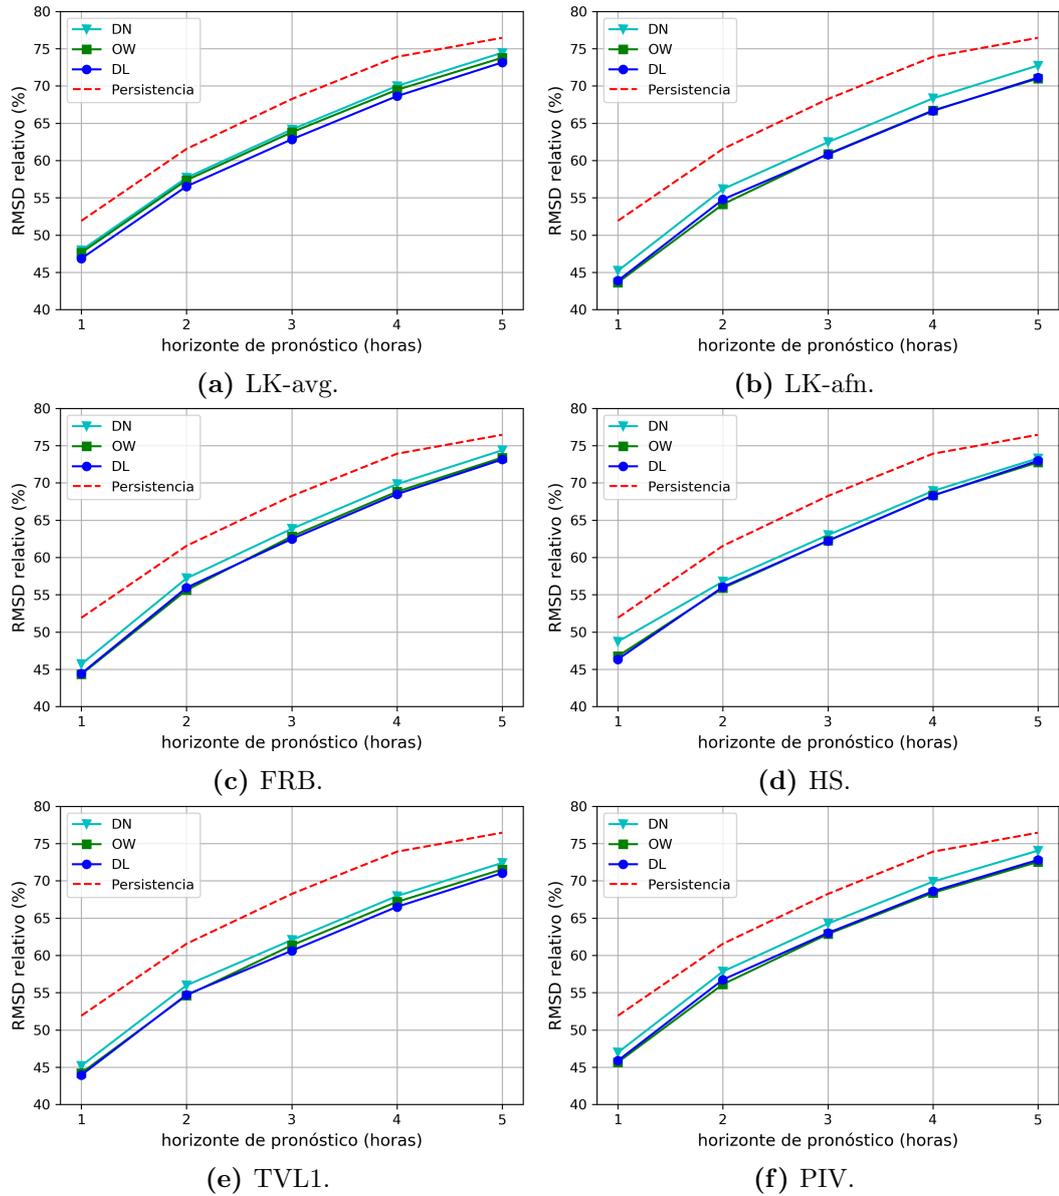


Figura 4.3: RMSD relativo de cada método utilizando diferentes estrategias de extrapolación para la generación de las imágenes pronosticadas.

h (hora)	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
método	MBD relativo (%)					RMSD relativo (%)					forecasting skill (%)				
LK-avg	+1.3	+1.6	-0.9	-4.9	-5.6	46.8	56.5	62.8	68.6	73.2	+9.7	+8.2	+7.9	+7.1	+4.3
LK-afn	+1.6	+2.0	-0.5	-4.6	-5.7	43.9	54.8	60.8	66.7	71.1	+15.5	+11.0	+10.9	+9.8	+7.0
FRB	+1.6	+1.7	-1.1	-5.7	-6.3	44.4	55.9	62.5	68.5	73.1	+14.4	+9.1	+8.5	+7.3	+4.3
HS	+0.4	+0.5	-2.9	-7.3	-9.0	47.5	55.5	61.6	67.5	72.0	+10.7	+9.0	+8.8	+7.6	+4.6
TVL1	+0.8	+0.9	-2.1	-6.4	-7.7	43.9	54.7	60.6	66.5	71.0	+15.3	+11.1	+11.2	+10.0	+7.1
PIV	+1.5	+1.7	-0.2	-3.7	-3.8	45.9	56.7	63.0	68.6	72.8	+11.6	+7.8	+7.7	+7.2	+4.8
persistencia	+2.1	+1.1	+0.3	-1.7	-5.0	51.1	61.2	67.5	72.8	76.7	-	-	-	-	-

Tabla 4.2: Desempeño de pronóstico a nivel de imagen en función del horizonte de pronóstico para cada método utilizado. La referencia promedio (albedo) es $\bar{\rho}_p = 0.28$.

se da en la primer hora. En la Figura 4.4b, se puede ver de mejor manera cómo se separan estos dos métodos del resto. LK-avg, HS y PIV son los que tienen peor desempeño en general. En cuanto a FRB, tiene un buen desempeño en RMSD relativo en la primer hora de pronóstico, pero luego decae para los siguientes horizontes de pronóstico, quedando a la par de HS y PIV para los últimos dos horizontes de predicción.

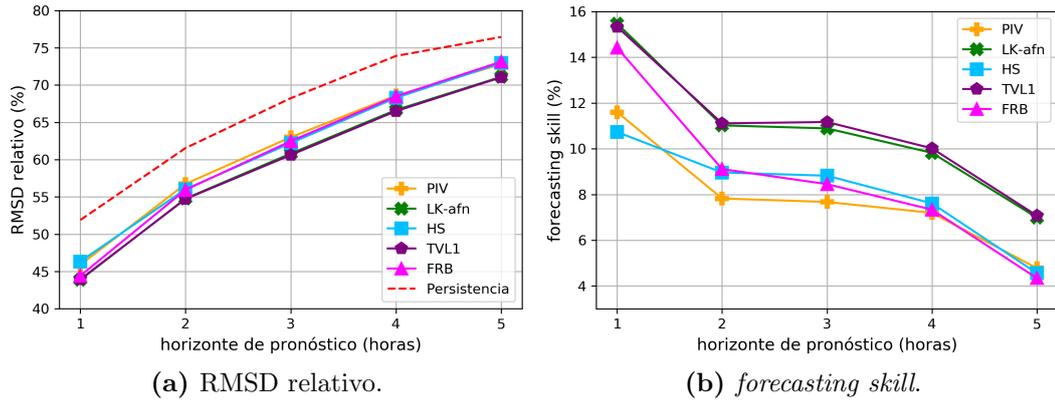


Figura 4.4: Desempeño de pronóstico a nivel de imagen en función del horizonte de pronóstico para cada método utilizado.

Se analizó también cómo varía el desempeño en función del nivel de nubosidad. En la Figura 4.5 se muestra cómo varía el RMSD relativo del método TVL1 respecto al albedo promedio de las imágenes. Se observa que las imágenes con menor albedo (menor presencia de nubes) son más fáciles de predecir, y viceversa para las de mayor presencia de nubes. Por ejemplo, con horizonte de pronóstico de 1 hora (Figura 4.5a), los valores de RMSD relativo varían entre 15-20% para albedo $\bar{\rho} \simeq 10\%$. Luego, a medida que el albedo aumenta, el valor de RMSD relativo se incrementa ($\bar{\rho} = 10-35\%$) hasta llegar a estabilizarse ($\bar{\rho} = 35-40\%$) y para valores más grandes de albedo ($\bar{\rho} > 40\%$) el resultado tiende a mostrar una pequeña mejora. Esto último se debe a que imágenes muy nubladas son un poco más sencillas de predecir que imágenes con nubosidad intermitente. Estos comportamientos también se ven reflejados al aumentar el horizonte de pronóstico (Figuras 4.5b y 4.5c), aunque con más dispersión y mayores valores de RMSD. Se puede concluir que el mejor desempeño de pronóstico a nivel de imagen se da en los valores extremos del albedo y el peor desempeño se da en los valores intermedios, incrementando la incertidumbre con el horizonte de pronóstico.

Comparando LK-avg con LK-afn, se observa un mejor desempeño del método

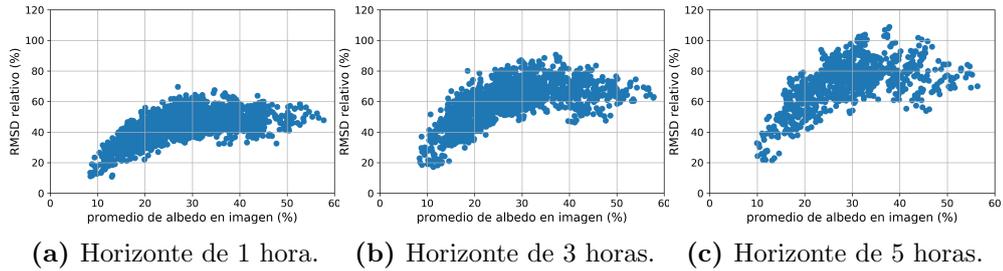


Figura 4.5: RMSD relativo en función del albedo de imágenes (método TVL1).

do LK-afn, por lo que se prefiere LK-afn sobre LK-avg y se decide desestimar LK-avg de estudios posteriores para simplificar los gráficos.

4.5. Evaluación a nivel de GHI

La sección anterior discute la evaluación a nivel de imagen (predicción de albedo píxel a píxel). Se tienen entonces las imágenes pronosticadas restando estudiar cuál es la predicción de irradiación solar asociada a cada píxel de estas imágenes, es decir, convertir el albedo pronosticado a un pronóstico de irradiación. Esta evaluación es posible en los puntos geográficos donde se tienen medidas de tierra (Tabla 3.3) contra las que comparar. El valor estimado en un punto dado se obtiene mediante la aplicación del modelo CIM-ESRA detallado en la Sección 3.4.1.

Cabe destacar que cuando se habla de punto, esto no necesariamente refiere a la información del píxel de la imagen que contiene a ese punto. Es posible, por ejemplo, utilizar la información espacial en un entorno del punto para mejorar la predicción horaria. Esto se debe a que la imagen contiene información instantánea (ubicación de las nubes para el instante de tiempo específico) y la predicción es del promedio en la hora. Por tanto, se puede asumir una hipótesis ergódica, donde se utiliza un promedio espacial de la imagen en el entorno del punto objetivo, de modo que dicho promedio represente mejor lo ocurrido en la hora que el valor instantáneo del píxel. Esta idea se utiliza regularmente en la estimación satelital de irradiación horaria a tiempo t (sin pronóstico) Alonso-Suárez (2017); Laguarda et al. (2020). En las siguientes subsecciones se evalúa el desempeño cuando se realiza la predicción utilizando la información del píxel, el promediado espacial óptimo de la estimación horaria, y un promediado espacial ajustado para cada horizonte de pronóstico, que además de aplicar la hipótesis ergódica, ayuda a lidiar con los errores de predicción,

especialmente para los horizontes más largos.

4.5.1. Predicción a nivel de píxel

Se evalúan los pronósticos de irradiación desde 1 a 5 horas utilizando la información en el píxel que contiene a cada sitio comentado en la Tabla 3.3. Se evalúan los diferentes métodos en su versión optimizada, y se compara contra la persistencia común en k_c (PERS) y la persistencia convexa (CC), que ya fueron introducidas en la Sección 2.2.1.

Como primer análisis, la Figura 4.6 muestra el desempeño de la predicción por TVL1 discriminado por estación. Se puede observar que el desempeño en cada estación es similar, siendo menor a $\pm 3\%$ respecto a la media en RMSD relativo. En cuanto al MBD relativo la dispersión es un poco menor, del orden $\pm 2\%$. La dispersión entre estaciones (espacial) existe, pero es pequeña, y es similar para el resto de los métodos. En lo que sigue, la comparación se realiza para el desempeño promedio entre estaciones, que se interpreta como el desempeño general en la región.

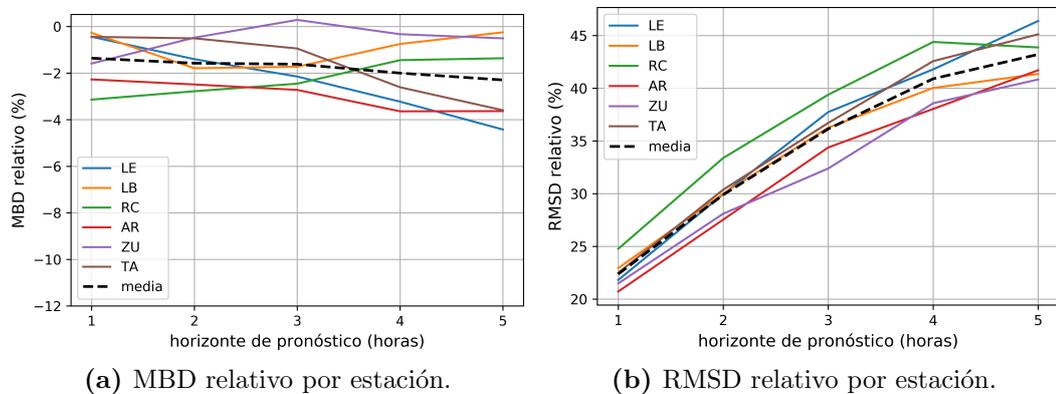


Figura 4.6: Desempeño del pronóstico TVL1 para irradiación solar en cada sitio.

La Tabla 4.3 muestra el desempeño general en la región para cada método y horizonte de pronóstico al utilizar la predicción *en el píxel* correspondiente a cada estación. En la Figura 4.7 se muestran los gráficos asociados a cada métrica de desempeño. Todos los métodos (y persistencias) tienden a subestimar el recurso solar. El método PIV es el que menos lo hace con un desvío medio menor al -1% en todos los horizontes de pronóstico. FRB y HS son los que más desvío medio tienen superando el -4% para horizontes de pronóstico de 4 y 5 horas. En cuanto al RMSD relativo, TVL1 es el método que tiene

mejor desempeño seguido de HS. Esto se visualiza mejor en el gráfico de FS (Figura 4.7c). En todas las métricas, a 1 hora, los valores de los métodos son muy similares. Al comparar los métodos con las persistencias, se observa que los métodos basados en flujo óptico logran mejorar a la persistencia común para la mayoría de los horizontes de predicción, pero ningún método logra mejor desempeño que la persistencia convexa (CC). Esto se ve claramente en el gráfico de FS (Figura 4.7c), el cual fue calculado utilizando la persistencia convexa como referencia. También se nota que, con horizonte de pronóstico de 1 hora, ningún método logra superar tampoco a la persistencia común. A partir del horizonte de 2 horas, salvo PIV, todos los métodos logran superar el desempeño de esta persistencia.

h (hora)	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
método	MBD relativo (%)					RMSD relativo (%)					<i>forecasting skill</i> (%)				
LK-afn	-1.6	-2.1	-2.5	-3.2	-3.2	23.0	31.1	37.3	42.7	45.2	-11.6	-4.8	-4.9	-8.9	-11.0
FRB	-1.5	-2.3	-3.1	-4.2	-4.4	22.9	31.4	38.1	43.3	45.5	-11.4	-5.8	-7.1	-10.6	-11.7
HS	-1.5	-2.2	-3.0	-4.1	-4.4	23.0	30.4	37.2	42.3	45.3	-11.5	-2.6	-4.5	-8.0	-11.3
TVL1	-1.4	-1.6	-1.6	-2.0	-2.3	22.4	29.9	36.1	40.9	43.2	-8.7	-0.8	-1.5	-4.3	-6.1
PIV	-1.0	-0.4	-0.2	-0.6	-0.5	23.4	32.6	40.0	45.4	47.7	-13.5	-9.8	-12.4	-15.7	-17.2
PERS	-0.8	-1.4	-2.1	-2.8	-3.0	21.2	31.4	38.8	43.8	46.5	-	-	-	-	-
CC	-0.8	-1.3	-1.9	-2.5	-2.6	20.6	29.7	35.6	39.2	40.7	-	-	-	-	-

Tabla 4.3: Métricas de desempeño para pronóstico de irradiación solar para cada método y persistencias.

El bajo desempeño de las técnicas se debe al uso únicamente de la información en el píxel. A continuación, se analizan las alternativas que utilizan los promedios espaciales, que mejoran significativamente el desempeño de la predicción horaria.

4.5.2. Incorporación de suavizado

El uso del promediado espacial en el contexto de pronóstico no es nuevo. En Kühnert et al. (2013), por ejemplo, se propone una etapa de suavizado de la imagen pronosticada. La intención, según los autores, es disminuir los errores al construir la imagen pronosticada y errores relacionados al movimiento y estructura de las nubes. Como se explicó antes, el promediado espacial también persigue mejorar la representación de lo ocurrido en una hora a partir de una imagen instantánea.

Se analizó el efecto de promediar en el espacio en celdas cuadradas en torno al sitio ($l \times l$). Se optimizó el tamaño de las celdas para cada método y horizonte de pronóstico, incluyendo el tiempo t ($h = 0$) como referencia. El

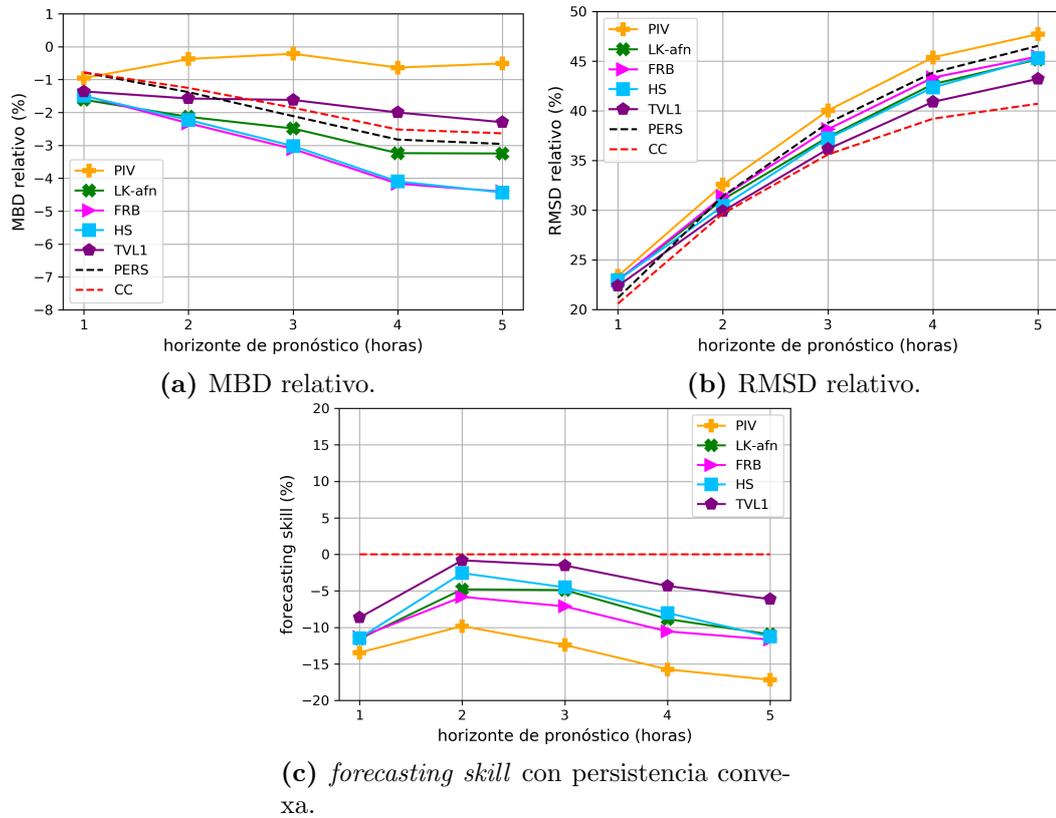


Figura 4.7: Desempeño de todos los métodos para pronóstico de irradiación solar.

tamaño óptimo de ventana es aquel que minimiza el error cuadrático medio entre la medida en tierra y la estimación/predicción de GHI, ambos a escala horaria. Se evalúa respecto al pronóstico de GHI ya que éste es el objetivo a mejorar, y del que se tiene la referencia de estimación a tiempo t , donde este procedimiento de promediado espacial se utiliza en forma corriente. En la Figura 4.8 se puede observar el resultado de este análisis para el método TVL1 (se indica con un cuadrado rojo el mínimo en cada horizonte de pronóstico, $h \in 0, 1, \dots, 5$). Se observa que el tamaño óptimo de la ventana de suavizado aumenta a medida que aumenta el horizonte de pronóstico, lo cual es coherente con la idea de que los errores se van incrementando en cada iteración. También se puede notar que el mínimo está mucho más marcado para valores menores de h y que para valores grandes, por ejemplo $h = 5$, el RMSD relativo es casi constante para rangos grandes de tamaños de ventana. Este comportamiento es similar en todos los métodos. Se pueden observar los diferentes resultados en el Apéndice D (Figura D.1).

En la Tabla 4.4 se detallan los valores óptimos para cada método. Los

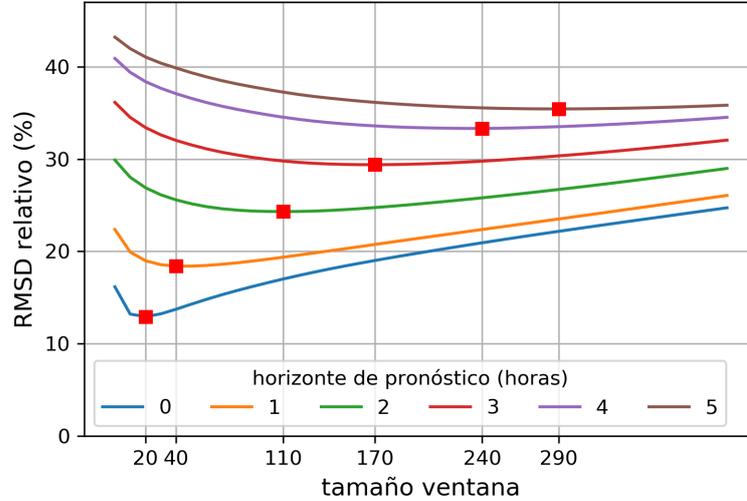


Figura 4.8: RMSD relativo como función del tamaño de celda l (método TVL1).

valores son parecidos en los distintos horizontes de pronóstico. También tienden a ser más disímiles para los horizontes más lejanos, dado que el punto óptimo es menos marcado. El valor para $h = 0$ es el mismo que el encontrado en otros trabajos (Laguarda et al., 2020) para el problema de estimación en la región con método CIM-ESRA (Sección 3.4.1). Para este valor se encontró un RMSD relativo de 12.9% para $h = 0$, lo cual es coherente con Laguarda et al. (2020) donde se obtiene un RMSD relativo de $\simeq 13\%$. Esto muestra que la optimización realizada es consistente con estudios previos. En la Tabla 4.5 se detallan los mismos valores pero con valores en kilómetros asumiendo la relación $1\text{px} \simeq 1.5\text{km}$ siendo esta una relación media.

h (hora)	0	1	2	3	4	5
método	Tamaño óptimo de ventana (l)					
LK-afn	20	50	120	180	240	290
FRB	20	50	140	200	270	330
HS	20	50	120	180	270	360
TVL1	20	40	110	170	240	290
PIV	20	50	120	190	250	320

Tabla 4.4: Tamaño óptimo de ventana (px) de suavizado para cada método.

Se analizaron dos alternativas, una de ellas utilizando el suavizado óptimo (ventana óptima según Tabla 4.4) para cada método y, la otra, tomando un suavizado constante (ventana fija) equivalente a la ventana óptima con $h=0$, esto es, una ventana de 20×20 px igual para todos los métodos y horizontes. En la Tabla 4.6 y la Tabla 4.7 se muestran, respectivamente, los resultados

h (hora)	0	1	2	3	4	5
método	Tamaño óptimo de ventana (l)					
LK-afn	30	75	180	270	360	435
FRB	30	75	180	300	405	495
HS	30	75	180	270	405	540
TVL1	30	60	165	255	360	435
PIV	30	75	180	285	375	480

Tabla 4.5: Tamaño óptimo de ventana (km) de suavizado para cada método.

para el caso de suavizado con ventana fija y para el caso de ventana óptima según el horizonte de pronóstico. En la Figura 4.9 se muestran estos resultados de forma gráfica.

h (hora)	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
método	MBD relativo (%)					RMSD relativo (%)					<i>forecasting skill</i> (%)				
LK-afn	-1.3	-1.9	-2.3	-3.0	-3.0	19.3	27.7	34.3	39.9	42.7	+6.1	+6.7	+3.8	-1.8	-5.0
FRB	-1.3	-2.1	-2.9	-4.0	-4.5	19.7	28.5	35.4	40.9	43.5	+4.1	+4.0	+0.5	-4.3	-7.0
HS	-1.3	-2.0	-3.0	-4.0	-4.5	19.3	27.4	34.5	40.0	43.2	+6.2	+7.5	+3.0	-2.0	-6.0
TVL1	-1.0	-1.2	-1.4	-1.9	-2.0	19.0	26.9	33.4	38.4	41.1	+7.8	+9.3	+6.1	+2.1	-0.9
PIV	-0.6	-0.1	+0.1	-0.4	-0.3	20.2	29.8	37.6	43.2	45.9	+2.0	-0.6	-5.6	-10.1	-12.7
CC	-0.8	-1.3	-1.9	-2.5	-2.6	20.6	29.7	35.6	39.2	40.7	-	-	-	-	-
PERS	-0.8	-1.4	-2.1	-2.8	-3.0	21.2	31.4	38.8	43.8	46.5	-	-	-	-	-

Tabla 4.6: Métricas de desempeño utilizando ventana fija de suavizado.

h (hora)	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
método	MBD relativo (%)					RMSD relativo (%)					<i>forecasting skill</i> (%)				
LK-afn	-0.9	-0.9	-1.2	-1.5	-1.2	18.6	24.8	30.0	34.2	36.8	+9.6	+16.4	+15.9	+12.7	+9.6
FRB	-1.0	-1.0	-1.6	-2.0	-1.7	19.0	25.5	30.6	34.5	36.5	+7.6	+14.1	+14.0	+12.0	+10.3
HS	-0.8	-0.9	-1.6	-2.3	-2.4	18.4	24.4	29.7	34.2	36.6	+10.7	+17.9	+16.5	+12.9	+10.1
TVL1	-0.7	-0.3	-0.3	-0.4	-0.2	18.4	24.3	29.4	33.3	35.4	+10.6	+18.0	+17.4	+15.0	+13.0
PIV	-0.2	+0.7	+1.0	+1.0	+1.5	19.4	27.1	33.2	37.5	39.9	+5.7	+8.8	+6.7	+4.3	+2.0
CC	-0.8	-1.3	-1.9	-2.5	-2.6	20.6	29.7	35.6	39.2	40.7	-	-	-	-	-
PERS	-0.8	-1.4	-2.1	-2.8	-3.0	21.2	31.4	38.8	43.8	46.5	-	-	-	-	-

Tabla 4.7: Métricas de desempeño utilizando ventana óptima de suavizado para cada método y horizonte de pronóstico.

Como era esperable, el mejor desempeño ocurre con el suavizado con ventana óptima. Su ganancia es importante, tanto en MBD como RMSD. También es interesante el caso con suavizado de ventana fija, debido a su practicidad. Por ejemplo, la técnica TVL1 con ventana fija es la única que logra superar a la persistencia en casi todos los horizontes de pronóstico ($FS > 0$).

Se analiza el desempeño de los métodos comparando también con el caso sin suavizado comentado en la Sección 4.5.1. Respecto al MBD relativo, en el caso de ventana fija no se notan cambios importantes respecto al caso sin suavizado. En el caso con ventana óptima, se nota un aplanamiento de las curvas de cada

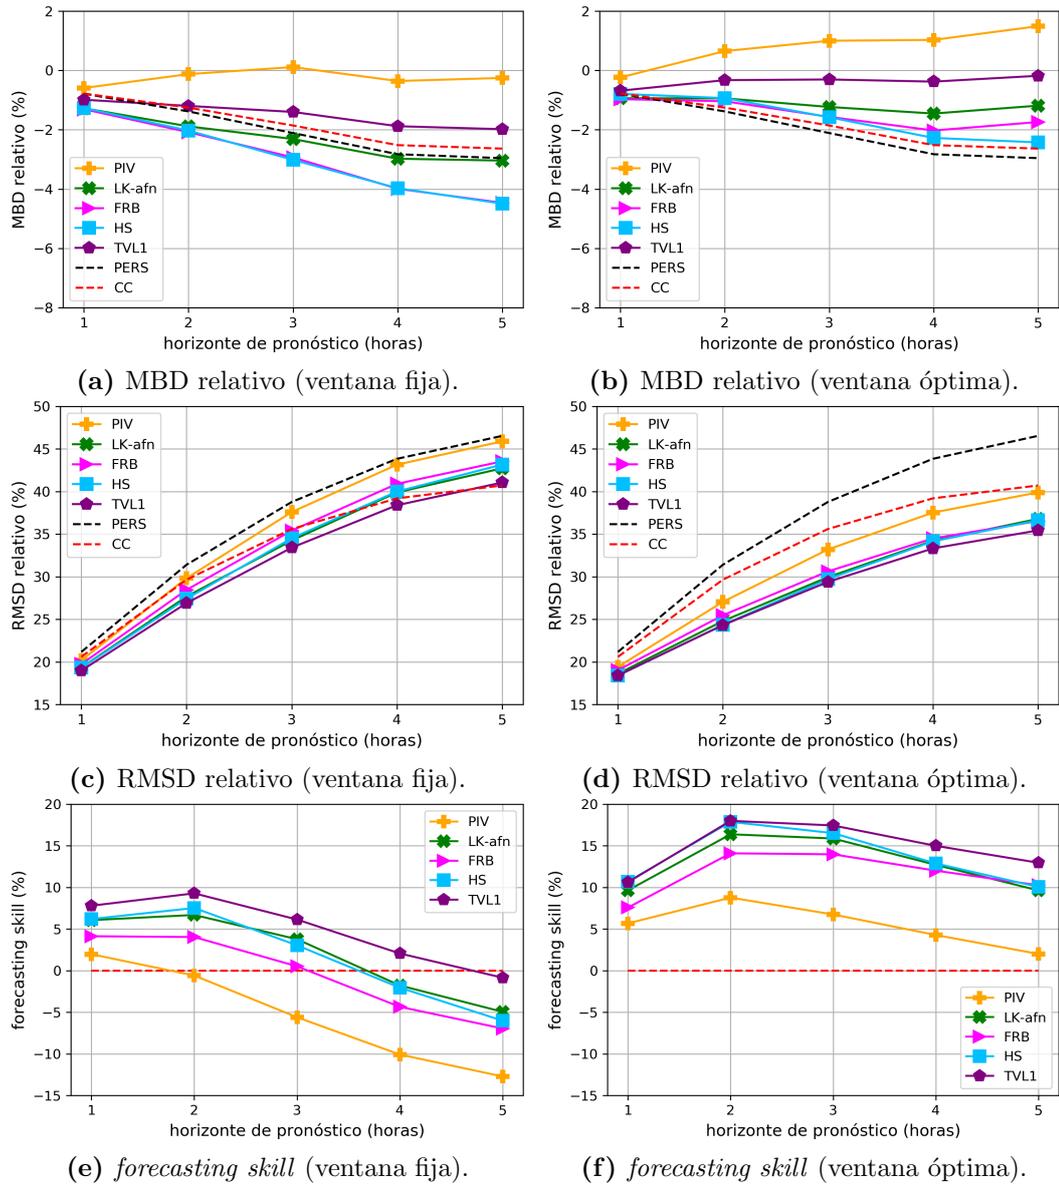


Figura 4.9: Comparación del desempeño a nivel de irradiación para todos los métodos de pronóstico.

método respecto al horizonte de pronóstico, donde sobresalen dos métodos, PIV porque es el único método que sobreestima en promedio y el TVL1 por ser casi inesgado ($MBD \simeq 0$). Respecto a RMSD relativo, se notan mejoras más importantes. Recordemos que en la Sección 4.5 se encontró que ninguno de los métodos lograba vencer a la persistencia convexa en ningún horizonte de pronóstico y con $h = 1$ ninguno lograba superar la persistencia en k_c . En el caso de ventana fija, todos los métodos logran vencer a la persistencia en k_c y salvo el método PIV. El resto de los métodos superan la persistencia convexa hasta

$h = 3$ y el TVL1 hasta $h = 4$, con un desempeño equivalente para el último horizonte ($h = 5$). PIV sólo supera a la persistencia convexa en $h = 1$. Aquí el mejor desempeño es el del método TVL1. Con ventana óptima el resultado es aún mejor, ya que todos los métodos superan el desempeño de la persistencia convexa. TVL1 sigue siendo el de mejor desempeño, aunque coincide en las dos primeras horas con el método HS. En cuanto a FS, recordando que se calcula respecto a la persistencia convexa, se puede observar claramente la mejora de aplicar el suavizado. Se observa el peor desempeño del método PIV respecto al resto de los métodos, y el mejor desempeño del método TVL1 aunque con ventajas marginales en las primeras horas de pronóstico, pero separándose del resto con pronósticos en $h = 4$ y $h = 5$. Se observa también cómo el suavizado con ventana óptima mejora el desempeño en forma más importante a partir de $h = 3$.

Considerando las métricas de desempeño, se concluye que la mejor estrategia para el pronóstico de GHI a corto plazo es la que utiliza el método TVL1 con suavizado con ventana óptima a nivel de imagen. Los efectos de suavizado a nivel de imagen para cada método, pueden observarse en Apéndice D (Figura D.3).

4.5.3. Impacto del suavizado

Seleccionando el método TVL1, y continuando con el análisis, se compara el desempeño de TVL1 medido con el error cuadrático medio. En la Figura 4.10 puede observarse el desempeño de TVL1 con las tres alternativas de suavizado en un único gráfico. Se observa el mejor desempeño de la estrategia de suavizado con ventana óptima, sobresaliendo al aumentar el horizonte de pronóstico. La acumulación de errores en los distintos horizontes previos, hace que, para horizontes mayores, se necesite un suavizado con ventana cada vez mayor.

En la Sección 2.3 se presentaron resultados referidos al desempeño de modelos numéricos de atmósfera intra-día en nuestra región. Se consideró que una buena aproximación de desempeño intra-día es tomarlo constante en todos los horizontes, con un RMSD relativo promedio 28.3% para el mejor modelo (ECMWF). En forma preliminar, debido a que la estadística temporal, controles de calidad y distribución de las muestras no es la misma en ambas comparaciones, se puede observar que el punto de corte (horizonte para el cuál

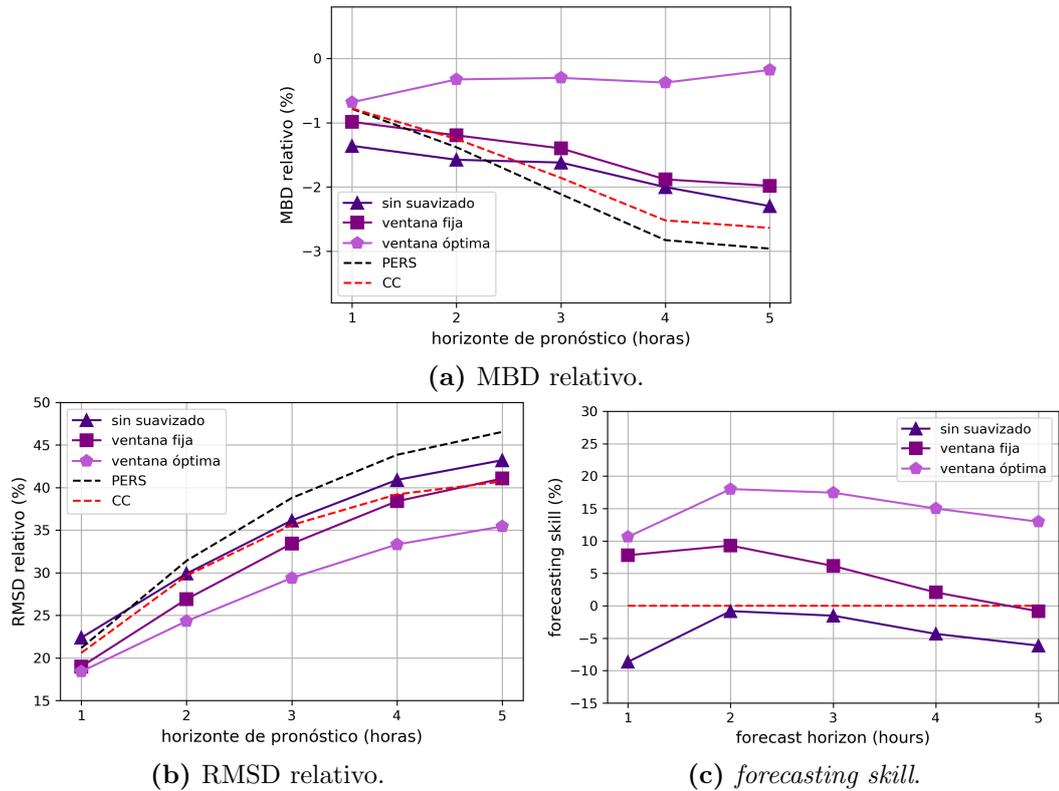


Figura 4.10: Comparación de desempeño de los métodos de predicción para el método TVL1, en los tres casos propuestos: sin suavizado, suavizado con ventana fija y suavizado con ventana óptima. PERS y CC son mostrados como referencia a la persistencia en k_c y la persistencia convexa respectivamente. FS es calculado en función de la persistencia convexa.

una u otra técnica tiene mejor desempeño) depende en forma importante del procedimiento de suavizado. El desempeño sin suavizado sólo logra mejorarlo en la primer hora de pronóstico. Por otro lado, el desempeño con ventana óptima tiene mejor desempeño hasta $h = 3$, donde coincide aproximadamente con el modelo ECMWF. Un trabajo reciente (Alonso-Suárez et al., 2022), que utiliza mismo período de tiempo de evaluación para la predicción satelital del LES y un NWP utilizado por ADME (pronóstico de la empresa Meteoblue), encontró el horizonte de transición entre $h = 3$ y $h = 4$. El método satelital operativo del LES utiliza el método FRB para estimación del CMV, búsqueda hacia atrás con interpolación bilineal para la extrapolación recursiva de imágenes, el modelo CIM-ESRA, y una combinación de predicciones por píxel único y ventana fija a nivel de albedo, no de predicciones de GHI. En este caso, la estrategia satelital utilizada no es la mejor, y el NWP tampoco es el de mejor desempeño en la región (Teixeira-Branco, 2023), habiendo más margen

de mejora para el primero. Los resultados, por tanto, siguen siendo preliminares. No obstante, son consistentes entre sí, y orientan a que este punto de transición se encuentra en $h \in [3, 5]$. Esto es además consistente con estudios internacionales, en el contexto de NWP's competitivos en la región.

4.5.4. Desempeño discriminado

A continuación se analizan en forma detallada los errores en el pronóstico de GHI en la estación LE, ya que es la que cuenta con instrumentos de mayor calidad para la medición en tierra. En Figura 4.11, Figura 4.12, Figura 4.13, se muestran los diagramas de dispersión entre los valores pronosticados y los valores medidos a nivel de tierra para esta estación en horizontes de pronóstico de 1-hora, 3-horas y 5-horas, respectivamente. Se ve claramente un aumento en la dispersión de los datos a medida que aumenta el horizonte de pronóstico. Respecto al suavizado, se nota una disminución de la dispersión en los casos en donde se utiliza el suavizado y mejora aún más en el caso de suavizado con ventana óptima.

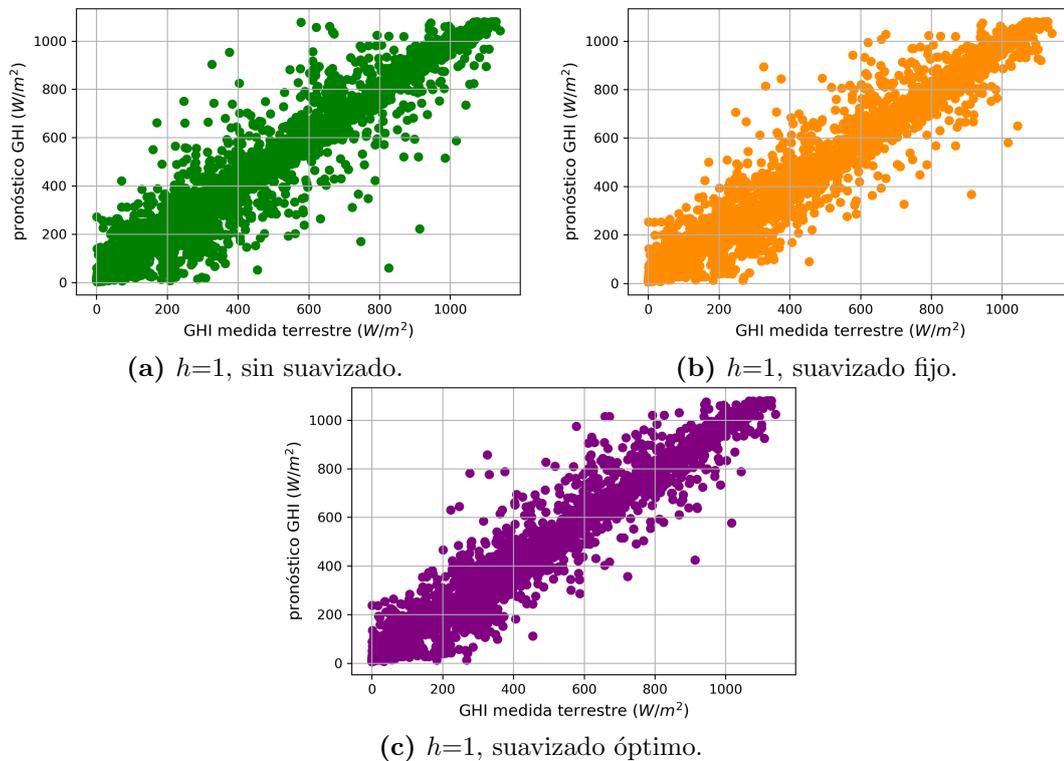


Figura 4.11: Diagramas de dispersión del pronóstico vs. las medidas para los 3 casos de suavizado según horizonte de 1 hora (estación LE).

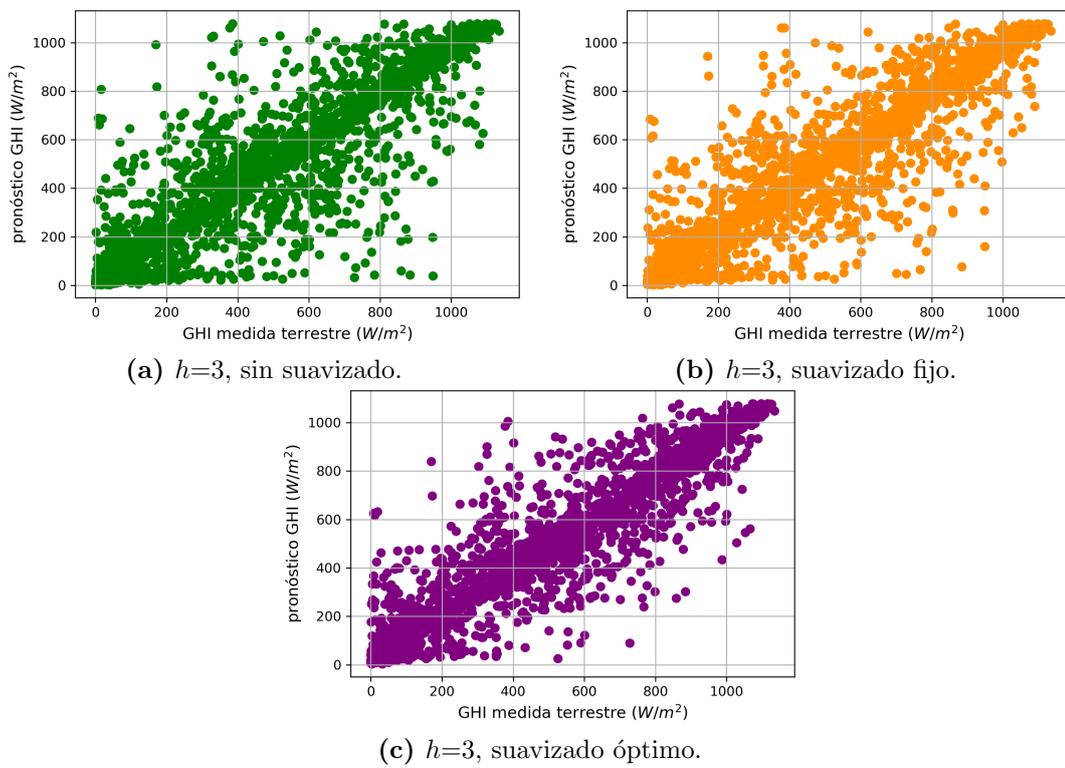


Figura 4.12: Diagramas de dispersión del pronóstico vs. las medidas para los 3 casos de suavizado según horizonte de 3 horas (estación LE).

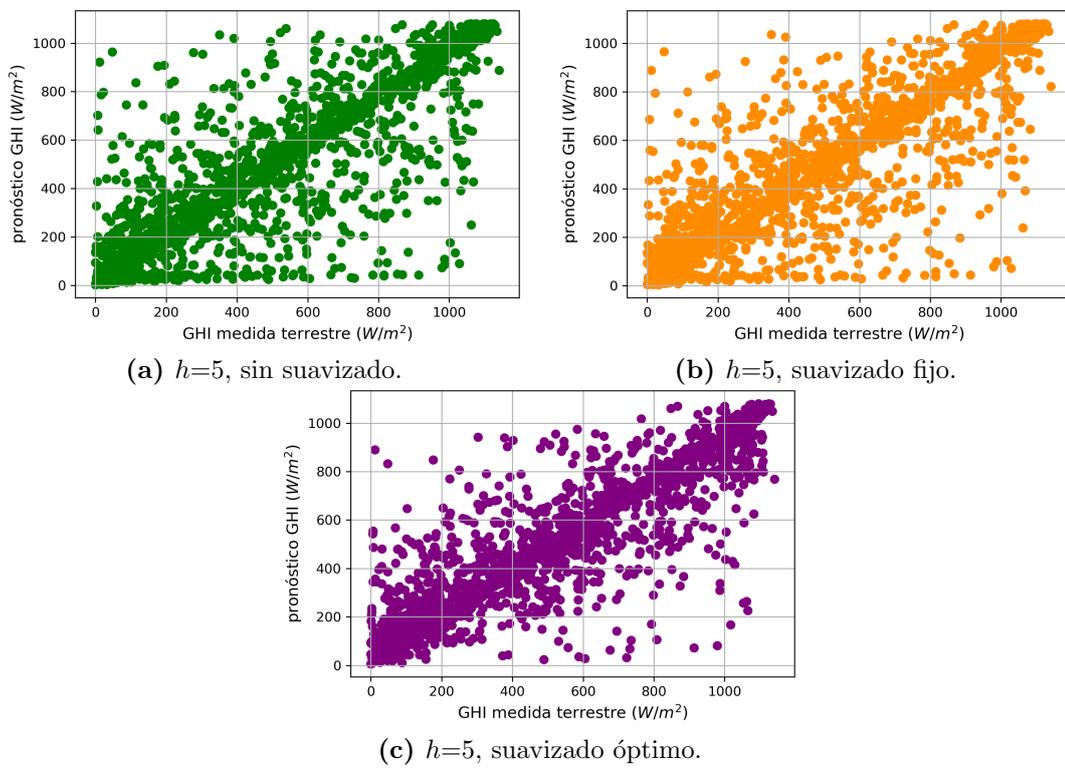


Figura 4.13: Diagramas de dispersión del pronóstico vs. las medidas para los 3 casos de suavizado según horizontes de 5 horas (estación LE).

Otro análisis interesante es observar los desempeños discriminados por el coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c). De esta forma se puede establecer cómo cambia el desempeño de acuerdo al momento del día (tiempo) y respecto a la nubosidad. El coseno del ángulo cenital mapea distintos momentos de día. Valores pequeños de $\cos\theta_z$ refieren al amanecer y atardecer, y valores más cercanos a 1 refieren a horas cercanas al mediodía solar de verano. El índice de cielo claro mapea distintas condiciones de nubosidad. Valores pequeños del índice ($k_c \leq 0.20$) refieren a cielo nublado y valores grandes ($k_c \geq 0.90$) refieren a cielo despejado. En Figura 4.14, Figura 4.15, Figura 4.16, se muestran el desvío medio relativo (MBD relativo) y en Figura 4.17, Figura 4.18, Figura 4.19, se muestran el desvío cuadrático medio relativo (RMSD relativo), discriminados por horizonte de pronóstico y por las cantidades antes mencionadas, con intervalos de paso 0.1 tanto en $\cos\theta_z$ como en k_c . El valor de $\cos\theta_z$ como el de k_c refieren al instante inicial de pronóstico, correspondiente a $h = 0$.

Respecto al MBD relativo, a medida que aumenta el horizonte de pronóstico, se nota un aumento del desvío medio, siendo esto más notorio para momentos más cercanos al mediodía solar y para k_c medios, es decir, cielo parcialmente nublado. Los mejores resultados se dan en condiciones de baja o alta nubosidad y en momentos cercanos al amanecer y atardecer. También puede observarse la mejora al aplicar el suavizado comparando las columnas.

Respecto al RMSD relativo, el desempeño es similar al desempeño de MBD relativo. El peor resultado se da en condiciones de cielo parcialmente nublado y cerca del mediodía solar. Esto ocurre también para la estimación a tiempo t (Alonso-Suárez et al., 2011; Laguarda, 2021). El desempeño empeora a medida que aumenta el horizonte de pronóstico. El efecto del suavizado es apreciable al comparar las columnas. Para $h = 1$ no se observa una clara diferencia al aplicar filtros.

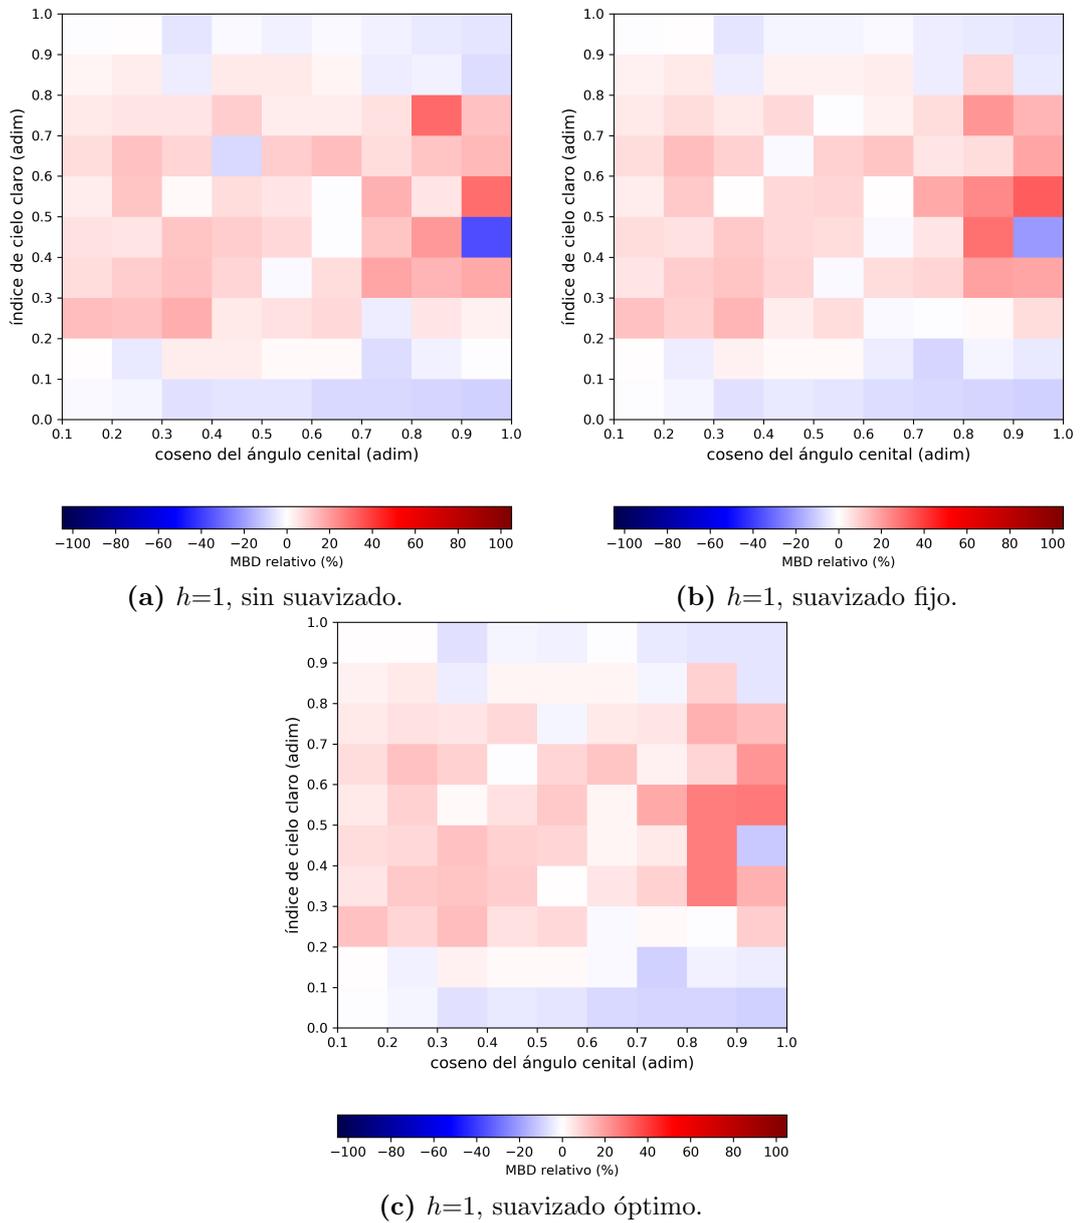


Figura 4.14: Desvío medio del pronóstico para los tres casos de suavizado según horizonte de 1-hora como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.

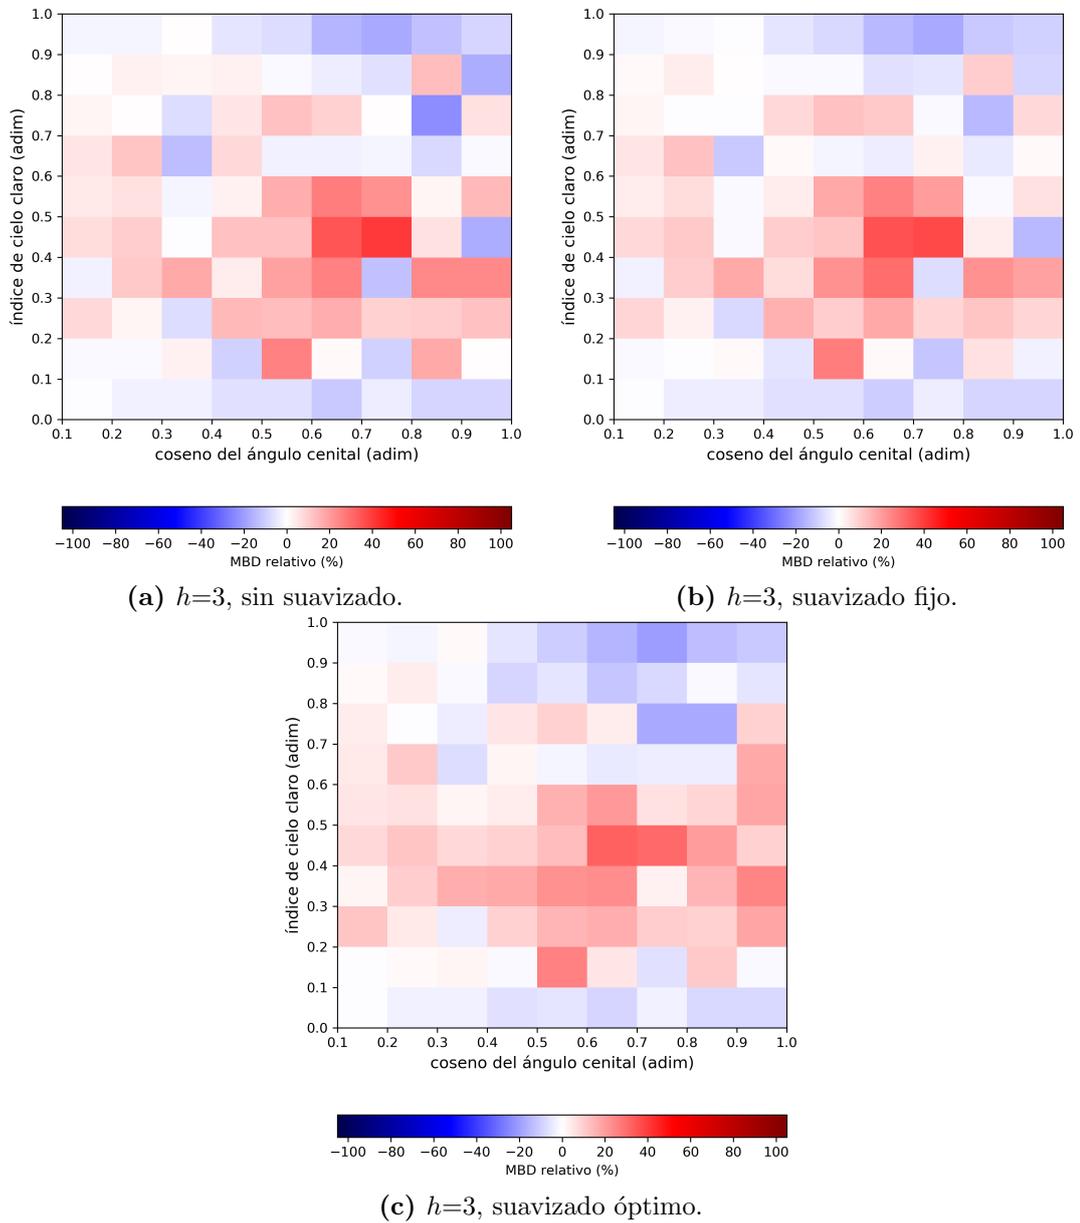
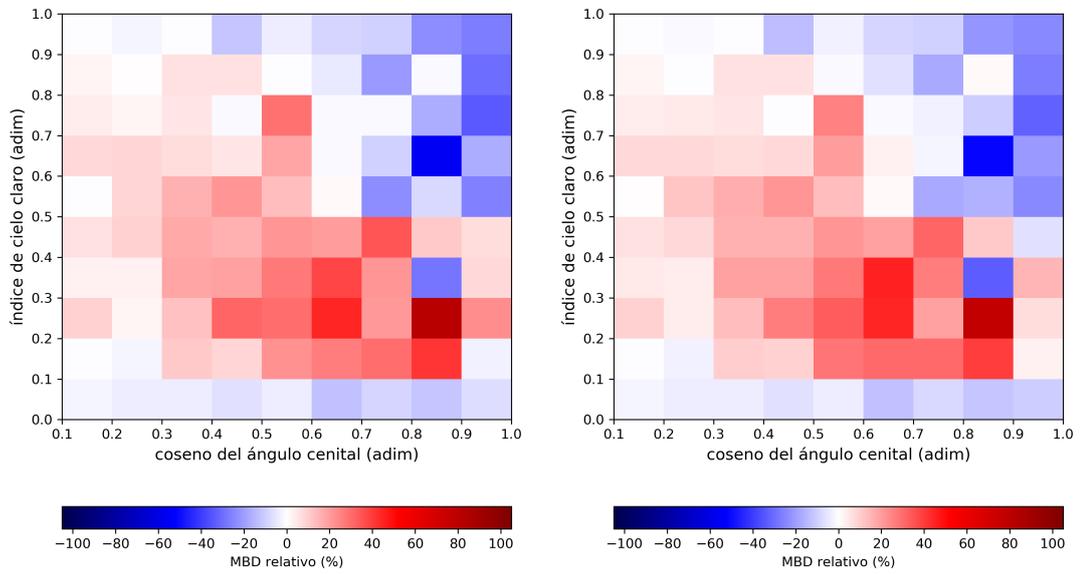
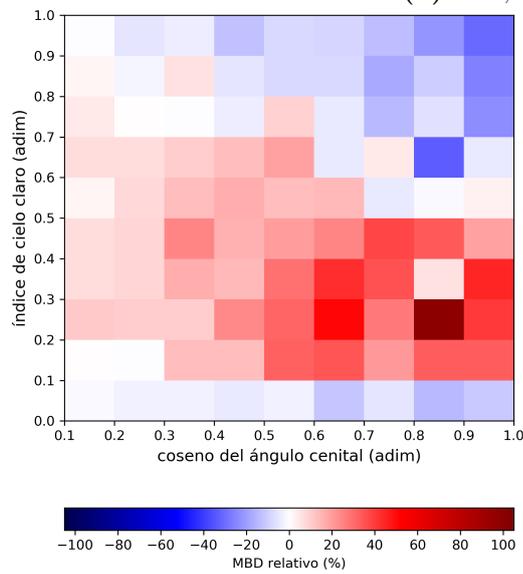


Figura 4.15: Desvío medio del pronóstico para los tres casos de suavizado según horizonte de 3-horas como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.



(a) $h=5$, sin suavizado.

(b) $h=5$, suavizado fijo.



(c) $h=5$, suavizado óptimo.

Figura 4.16: Desvío medio del pronóstico para los tres casos de suavizado según horizonte de 5-horas como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.

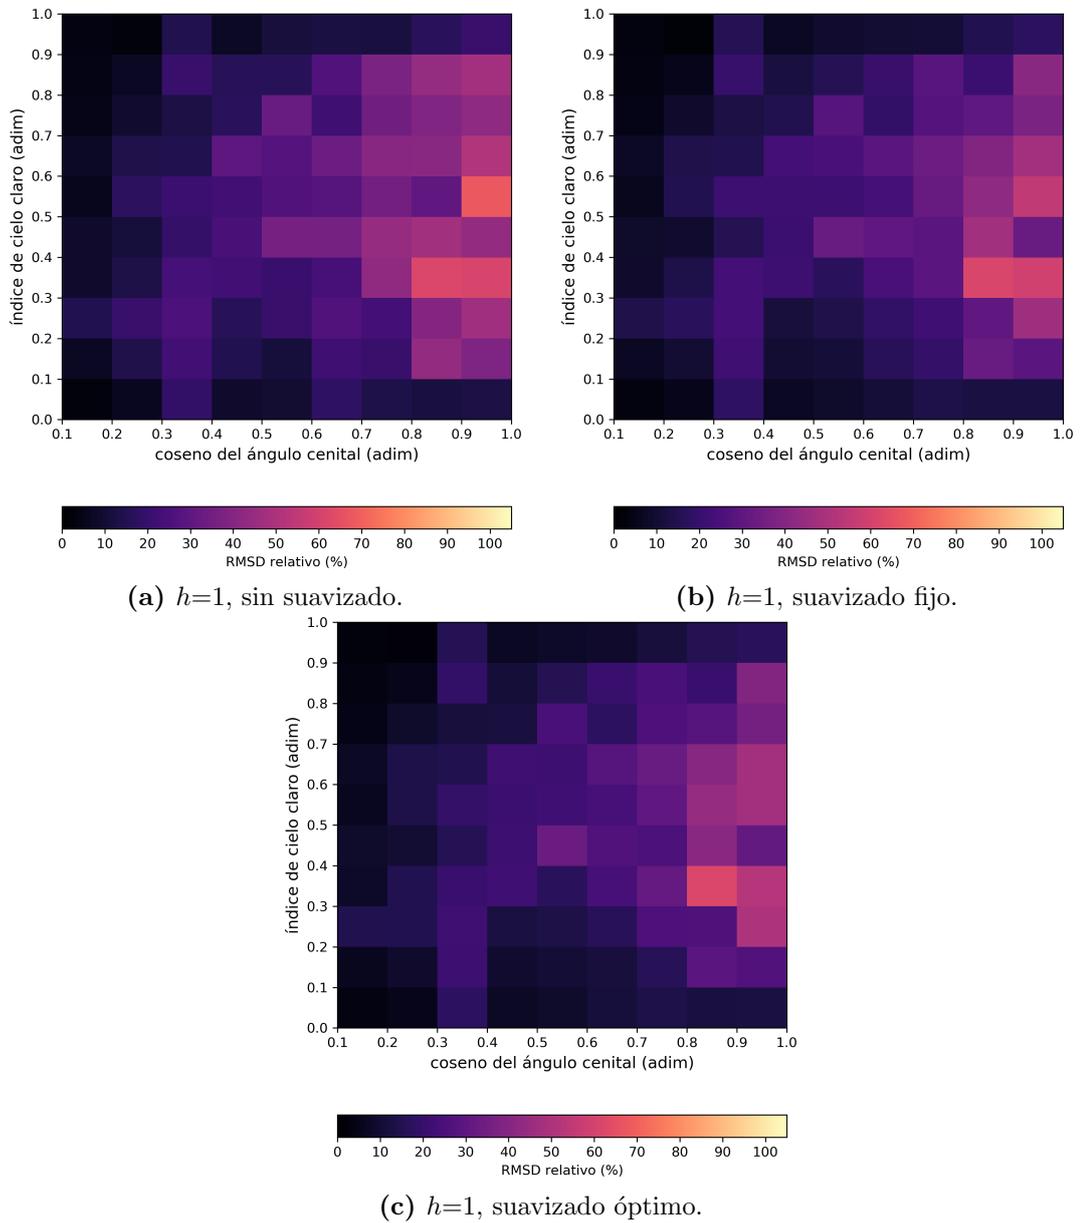


Figura 4.17: Desvío cuadrático medio del pronóstico para los 3 casos de suavizado según horizontes de 1-hora como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.

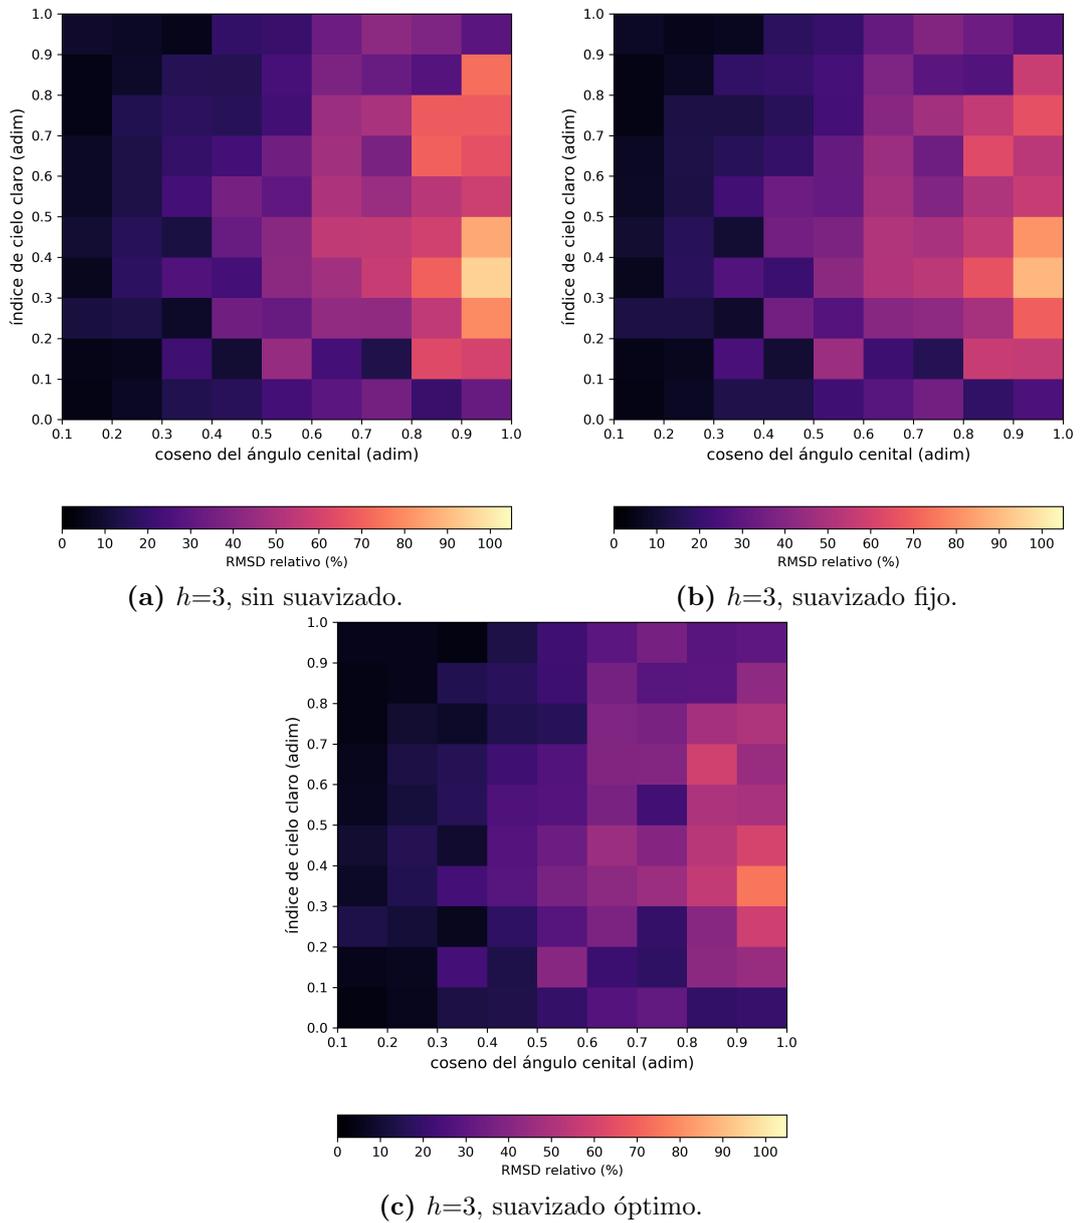


Figura 4.18: Desvío cuadrático medio del pronóstico para los 3 casos de suavizado según horizontes de 3-horas como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.

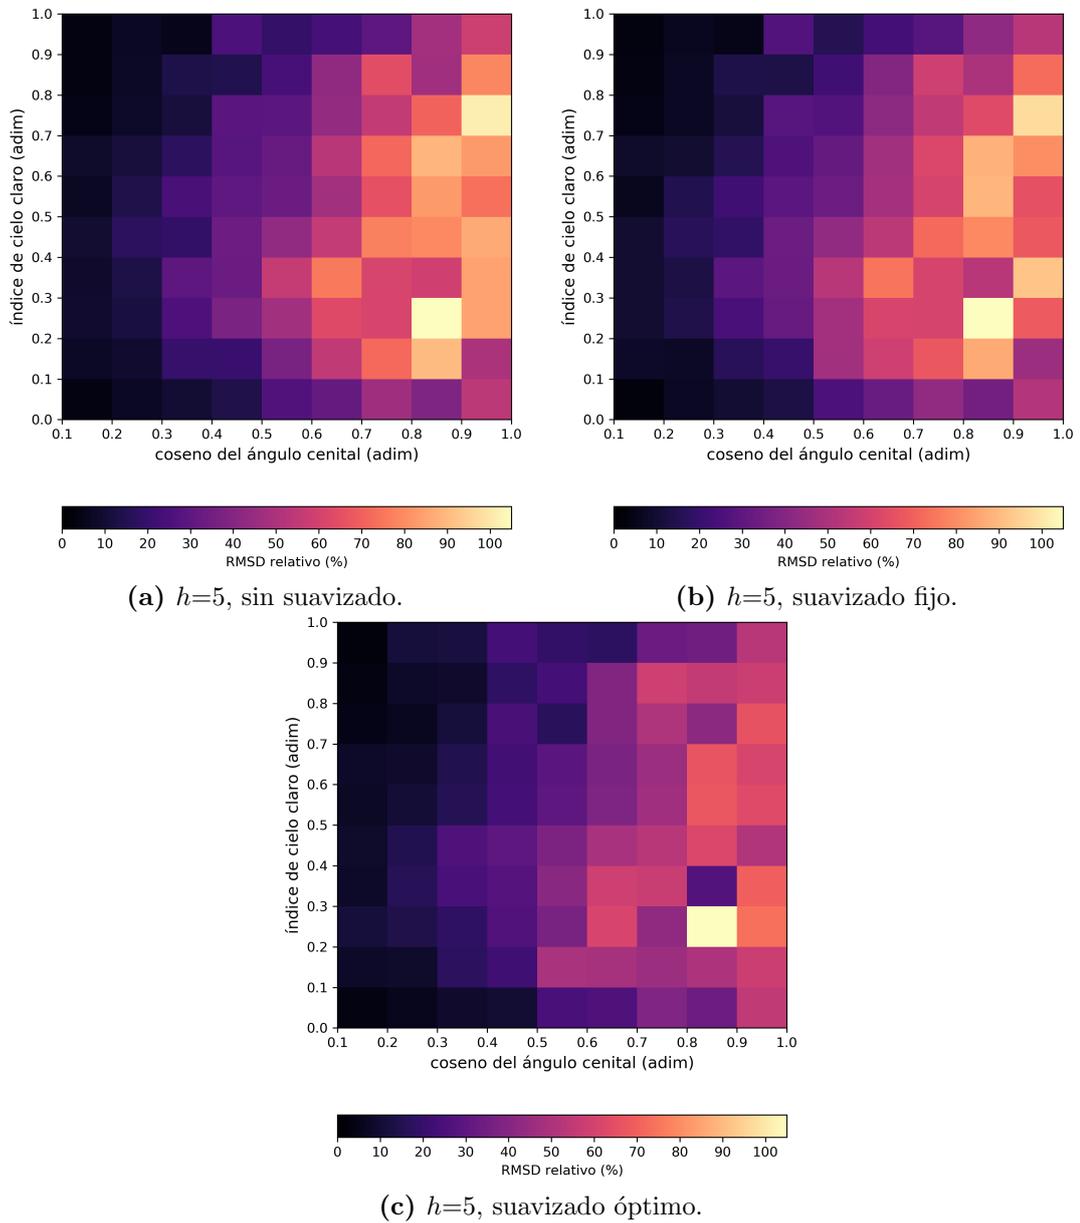


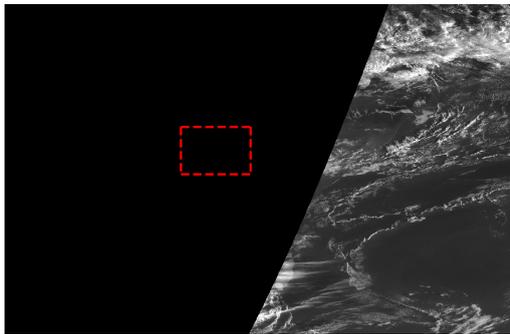
Figura 4.19: Desvío cuadrático medio del pronóstico para los 3 casos de suavizado según horizontes de 5-horas como función del coseno del ángulo cenital ($\cos\theta_z$) y el índice de cielo claro (k_c) para la estación LE.

4.5.5. Casos de estudio

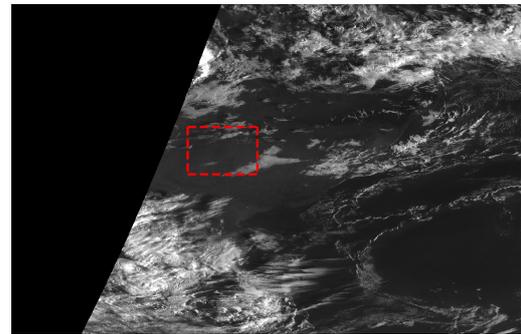
Considerando el método TVL1 para el cálculo del CMV y suavizado con ventana óptima a nivel de imagen, se analizan 5 días donde se contemplan 10 casos (en distintos momentos del día) sobre la estación terrestre LE. Estos casos incluyen desde condiciones de cielo claro o de muy poca nubosidad a condiciones de alta nubosidad en dos momentos del día: cerca del amanecer y cerca del mediodía solar. Momentos cercanos al atardecer llevan a predicciones nocturnas a futuro que son trivialmente nulas, y por eso no son analizados aquí. En todos los casos se considera también la persistencia convexa.

El primer día a analizar se muestra en la Figura 4.20. Observando las medidas de GHI a nivel de tierra, se trata de un día de cielo despejado sobre el sitio. Esto hace que el pronóstico, tanto de la persistencia convexa como de la estrategia sugerida, sea muy acertado. Al mantenerse condiciones similares al estado inicial, la persistencia se mantiene con un buen desempeño. El pronóstico satelital con inicio a la hora 7 (Figura 4.20d) tiene un peor desempeño que la persistencia convexa. Esto se debe a que si observamos el estado del cielo a la hora 7 (Figura 4.20b), se tiene una zona oscura correspondiente al amanecer, la cual no da información sobre nubosidad en esos puntos. Si además se considera la imagen anterior (con la que se calcula el CMV), en la Figura 4.20a se nota la falta de información para la zona de interés. Esa falta de información hace que el pronóstico no pueda inferir de manera acertada el CMV y por lo tanto, tampoco sea adecuado para el pronóstico.

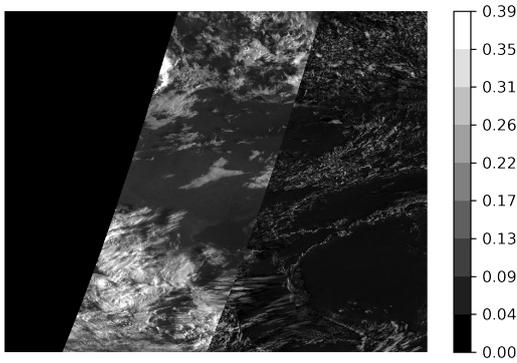
En la Figura 4.21 puede verse el pronóstico con inicio a la hora 8 y se puede notar como, ahora sí, el pronóstico satelital se desempeña correctamente. Esto es debido a que a la hora 8 ya se cuenta con mayor información espacial y el cielo en el entorno está más despejado. Para la hora 11 (Figura 4.22), con toda la información conocida, el desempeño del pronóstico satelital es mejor que el de persistencia convexa. El pronóstico dado por la persistencia convexa es bueno en ambos casos, ya que las condiciones del cielo no variaron en el horizonte de pronóstico por ser un día casi despejado.



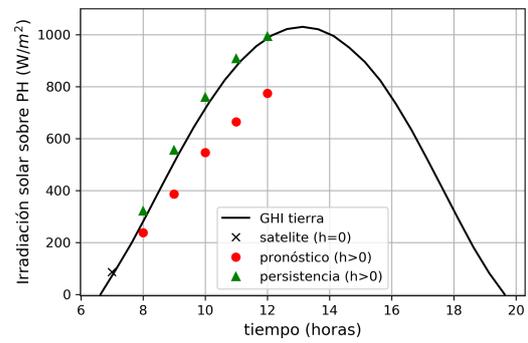
(a) imagen hora 6:30.



(b) imagen hora 7:00.

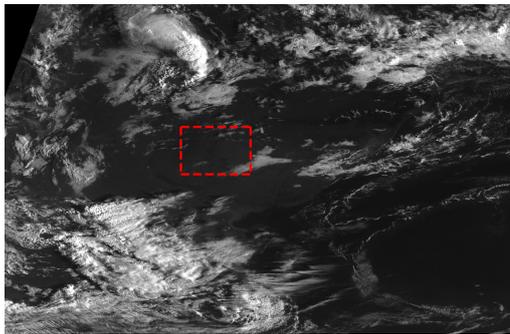


(c) diferencia absoluta entre imágenes.

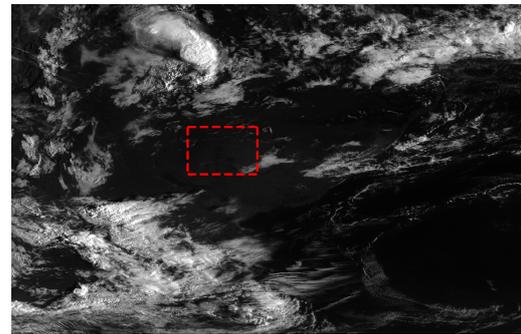


(d) pronóstico inicio hora 7:00.

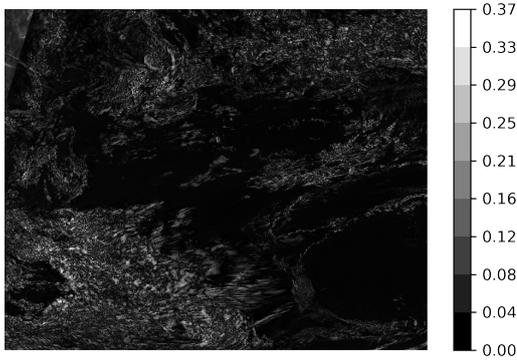
Figura 4.20: Pronóstico de GHI día 11/02/2016 con inicio hora 7:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.



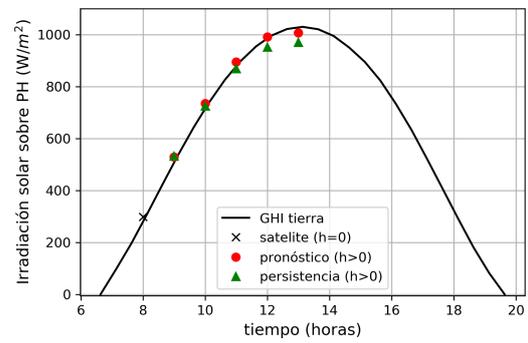
(a) imagen hora 7:30.



(b) imagen hora 8:00.

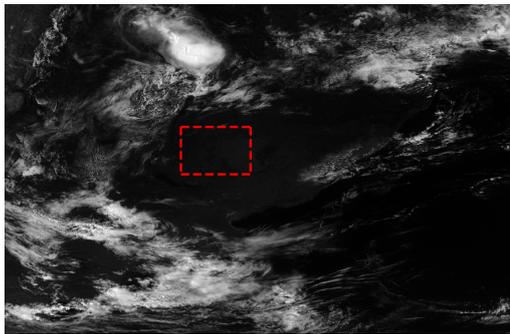


(c) diferencia absoluta entre imágenes.

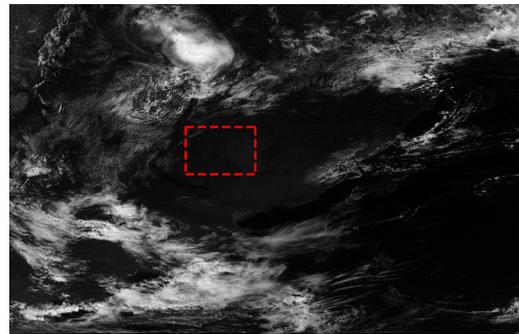


(d) pronóstico inicio hora 8:00.

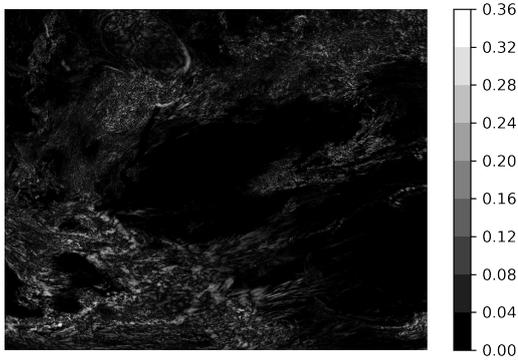
Figura 4.21: Pronóstico de GHI día 11/02/2016 con inicio hora 8:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.



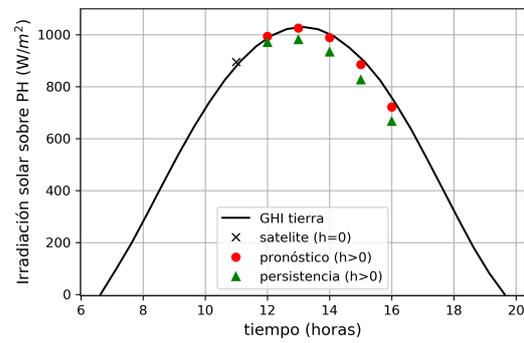
(a) imagen hora 10:30.



(b) imagen hora 11:00.



(c) diferencia absoluta entre imágenes.



(d) pronóstico inicio hora 11:00.

Figura 4.22: Pronóstico de GHI día 11/02/2016 con inicio hora 11:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

Otro día se muestra en la Figura 4.23. Este es un día con nubosidad parcial y mayor variabilidad sobre el mediodía. El pronóstico con inicio a la hora 7 (Figura 4.23d) muestra un mejor desempeño de la estrategia satelital respecto de la persistencia convexa. También, en ambos casos, se nota una subestimación del recurso solar a medida que se aumenta el horizonte de pronóstico. También se nota el momento de variabilidad del recurso en $h = 4$ y $h = 5$ que es donde más se subestima. Este día, al igual que el anterior, la imagen previa (Figura 4.23a) tiene faltante de información, pero en este caso, sí hay información en la zona de interés y es por esto que el pronóstico es bueno para las primeras horas. Para el inicio a la hora 11 (Figura 4.24), el pronóstico satelital es más acertado ya que las condiciones de cielo aparentan ser de horas claras.

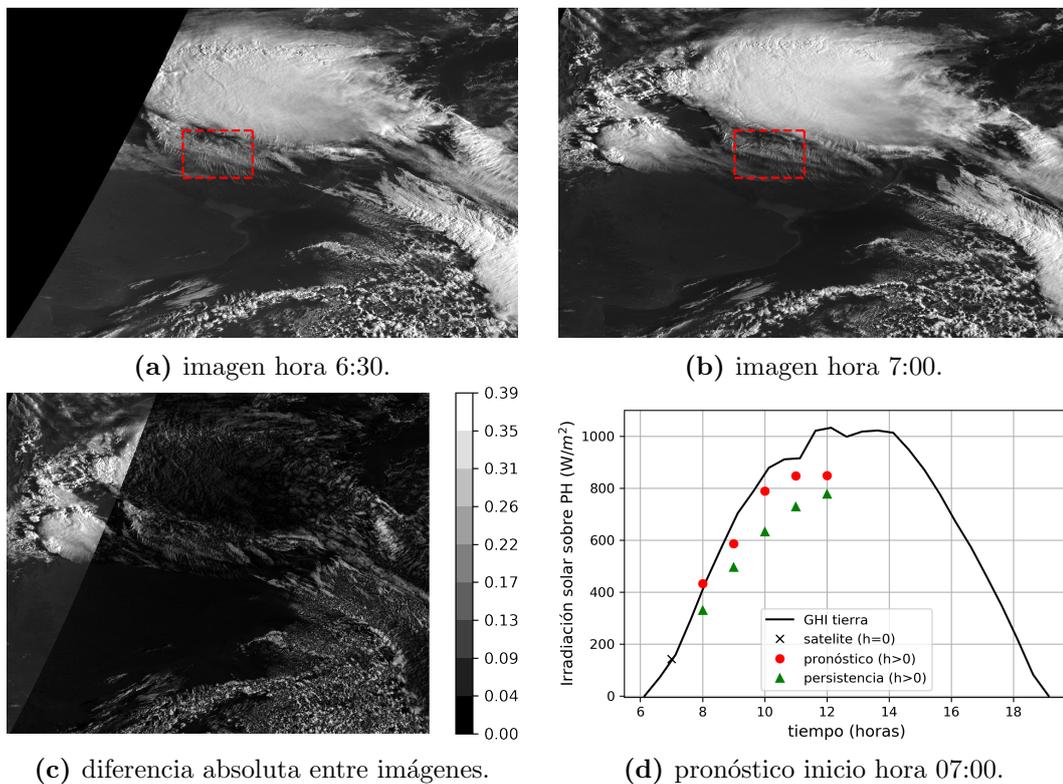
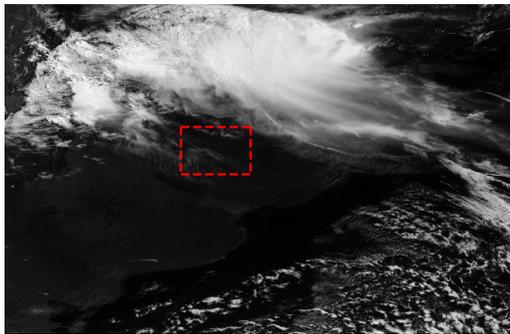
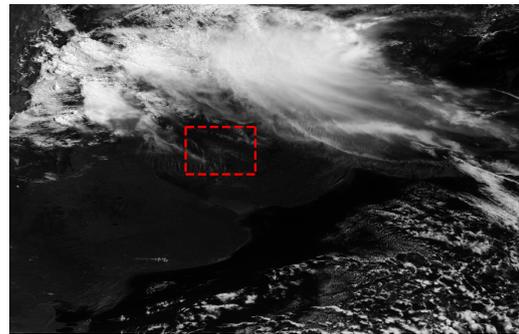


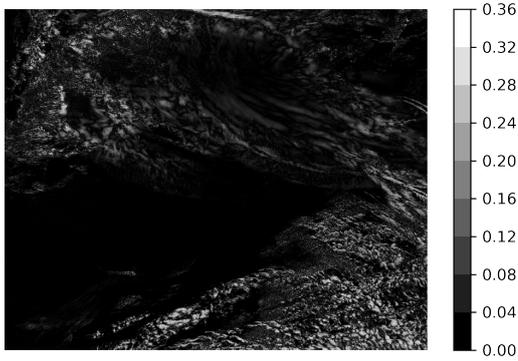
Figura 4.23: Pronóstico de GHI día 11/11/2016 con inicio hora 7:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.



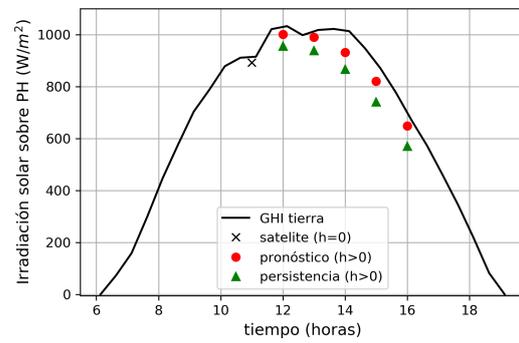
(a) imagen hora 10:30.



(b) imagen hora 11:00.



(c) diferencia absoluta entre imágenes.



(d) pronóstico inicio hora 11:00.

Figura 4.24: Pronóstico de GHI día 11/11/2016 con inicio hora 11:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

El siguiente día (Figura 4.25) es el de un día nublado que tiene un comportamiento en la mañana y otro muy distinto después de las 11 horas. Comienza con muy poca variabilidad y nubosidad constante, y luego el recurso solar cae abruptamente (alta nubosidad) y aumenta la variabilidad. El pronóstico satelital con inicio a la hora 11 (Figura 4.25d) es muy acertado respecto a los valores de tierra y respecto a la persistencia convexa. En un caso con mucha nubosidad, y la estrategia elegida tiende a captar toda esta nubosidad con los distintos tamaños de ventana. La persistencia convexa, por otra parte, erra el pronóstico al suponer que no van a haber cambios.

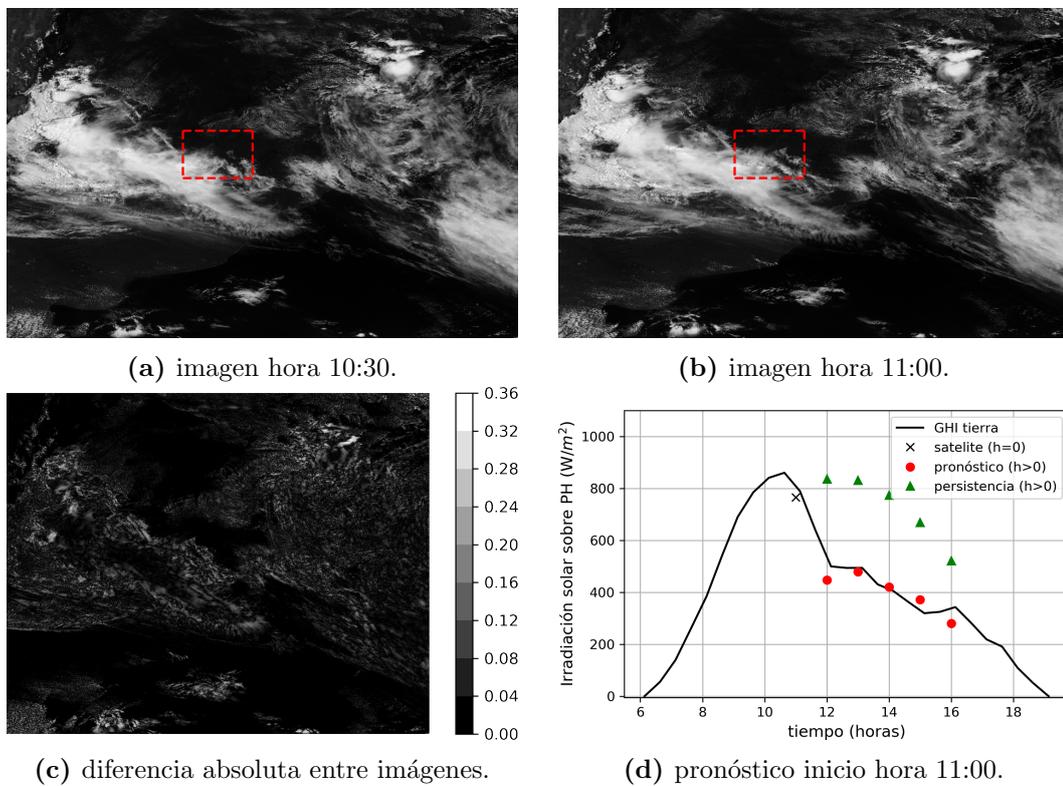


Figura 4.25: Pronóstico de GHI día 16/11/2016 con inicio hora 11:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

En la Figura 4.26 se analiza un día con alta nubosidad y variabilidad del recurso solar. El pronóstico con inicio en la hora 11 (Figura 4.26d) ya considera el estado inicial con alta nubosidad (Figura 4.26b) y por eso el error es menor. La persistencia convexa no se adapta a la variabilidad del recurso, mientras que la estrategia satelital se adapta mejor.

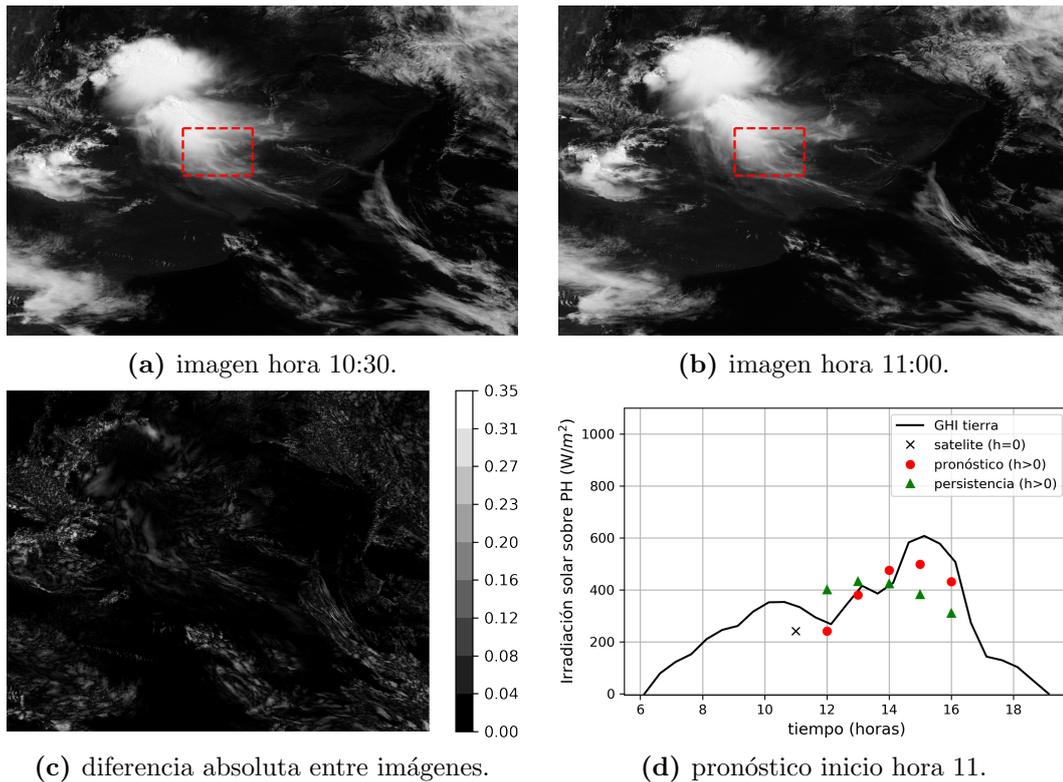


Figura 4.26: Pronóstico de GHI día 14/11/2016 con inicio hora 11:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

Finalmente, en la Figura 4.27 y Figura 4.28 se analiza un día con muy alta nubosidad y variabilidad del recurso solar. En el pronóstico con inicio a la hora 8 (Figura 4.27d) la estrategia de pronóstico satelital tiene un buen desempeño. Lo mismo sucede con inicio a la hora 11 (Figura 4.28d).

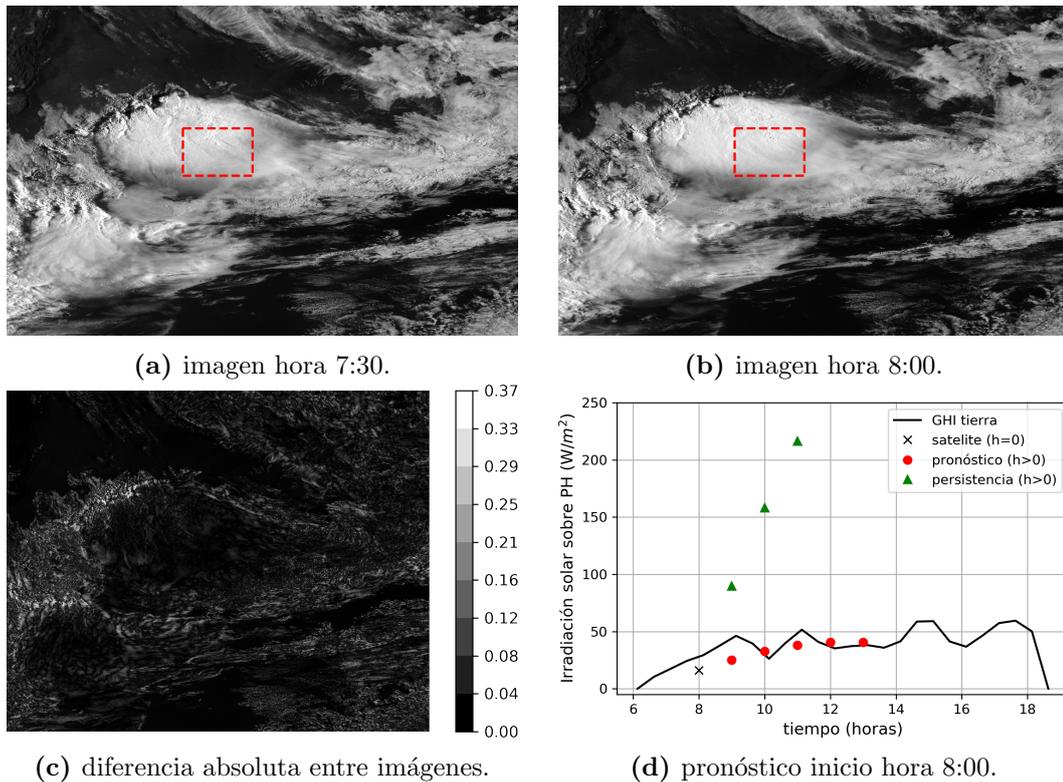


Figura 4.27: Pronóstico de GHI día 24/10/2016 con inicio hora 8:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

En todos los casos analizados puede observarse la gran dependencia que tiene la persistencia del estado del cielo en $h = 0$. En casos de poca variabilidad del recurso solar, este tipo de pronóstico tiene buen desempeño, pero en casos de variabilidad media y alta, el pronóstico por persistencia tiene un mal desempeño. En el caso de pronóstico satelital, se vio que para el caso de suavizado óptimo el pronóstico tiene buen desempeño promedio, pero algunos problemas en condiciones de cielo no homogéneas en un entorno del sitio objetivo. También tiene problemas cerca del amanecer debido a efectos de borde en las imágenes (este problema ocurre sólo en la mañana, no en la tarde). En la mayoría de los casos, cuando el horizonte de pronóstico aumenta, se tiende a subestimar el recurso debido al suavizado aplicado con ventanas cada

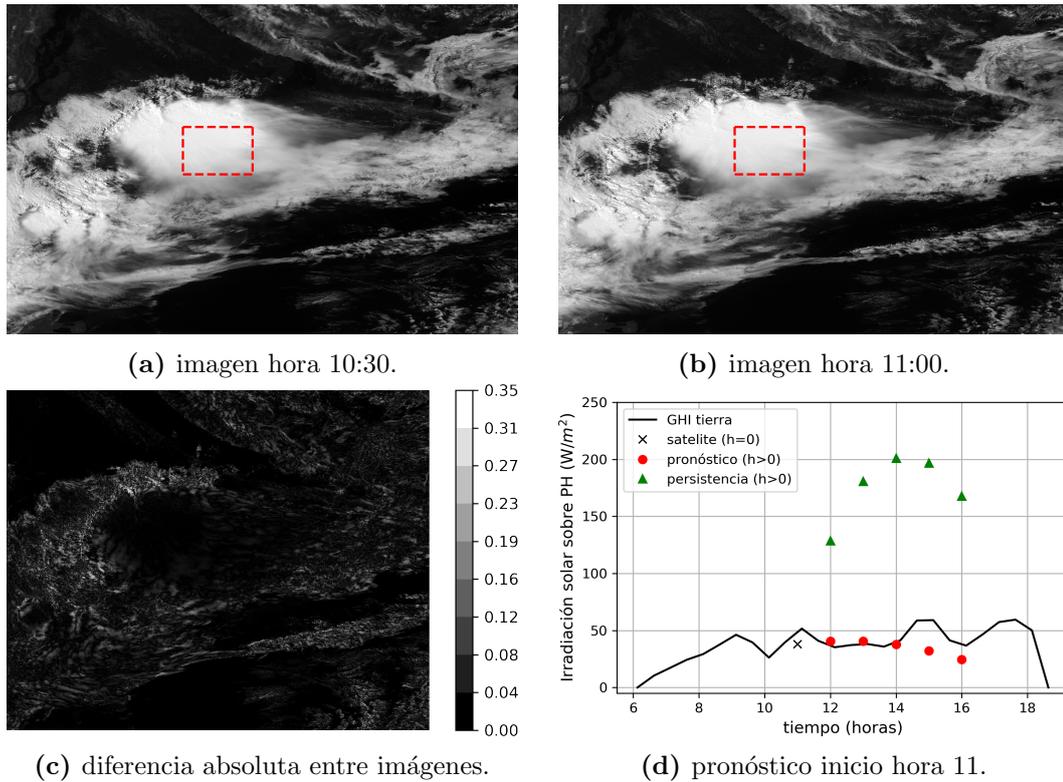


Figura 4.28: Pronóstico de GHI día 24/10/2016 con inicio hora 11:00. Se muestran los pronósticos respecto al valor medido en tierra y las imágenes satelitales correspondientes a las horas de inicio del pronóstico.

vez más grandes y el error más común es considerar nubosidad que no está presente sobre el sitio. También se observa que si bien tienden a seguirse de buena manera los casos de condiciones muy variables, el hecho de incluir un suavizado previo, hace que se pierda información de la variabilidad y esto se hace más notorio con horizontes de pronóstico más grandes. Se podría sugerir un suavizado con ventanas menores para, de esta forma, adaptarse más a la variabilidad del recurso, pero a la vez esto incrementaría los *outliers* con lo que baja el desempeño del pronóstico. Se manifiesta un compromiso entre adaptabilidad al cambio y desempeño.

4.6. Síntesis general del método

La opción que maximiza el desempeño de la predicción satelital es la estrategia con el método TVL1 para la estimación de CMV, extrapolación recursiva de imágenes con búsqueda hacia atrás e interpolación bilineal, y la utilización del suavizado de ventana óptima previo a la conversión de albedo en irradiación solar horaria.

Consideremos un proceso en régimen en el cual a medida que llegan imágenes satelitales, se calculan los pronósticos al muy corto plazo (1 a 5 horas) de GHI. El primer paso es la estimación de CMV, el cual considera las dos últimas imágenes recibidas y donde se utiliza el método TVL1. El segundo paso es donde se calculan los pronósticos en base al CMV calculado anteriormente. Primero se pronostica I_{p_1} (primer imagen pronosticada) con la información de I_0 (última imagen disponible) y del CMV, generando un pronóstico a nivel de imagen a 30 minutos. Luego, con el mismo CMV, se calculan el resto de los pronósticos a nivel de imagen con paso 30-minutal. En total se calculan 10 horizontes de pronóstico. De estos 10 pronósticos, sólo se consideran los pronósticos pares, que son los de paso horario. El tercer paso es el suavizado óptimo según el horizonte de predicción. El último paso es la estimación de GHI para cada horizonte de pronóstico (horario, de 1 a 5 horas) en toda la región (imagen GHI) o en una estación dada, utilizando el modelo CIM-ESRA (Laguarda et al., 2020). El resultado del procedimiento son 5 pronósticos horarios a partir del momento actual (el momento en el que llegó la última imagen). Se hace notar que este procedimiento es computable en el orden de segundos al llegar una nueva imagen, lo que habilita a su uso operativo para predicciones de irradiación solar. En la Figura 4.29, se esquematiza lo antes mencionado considerando las etapas de la obtención del pronóstico de GHI en una estación.

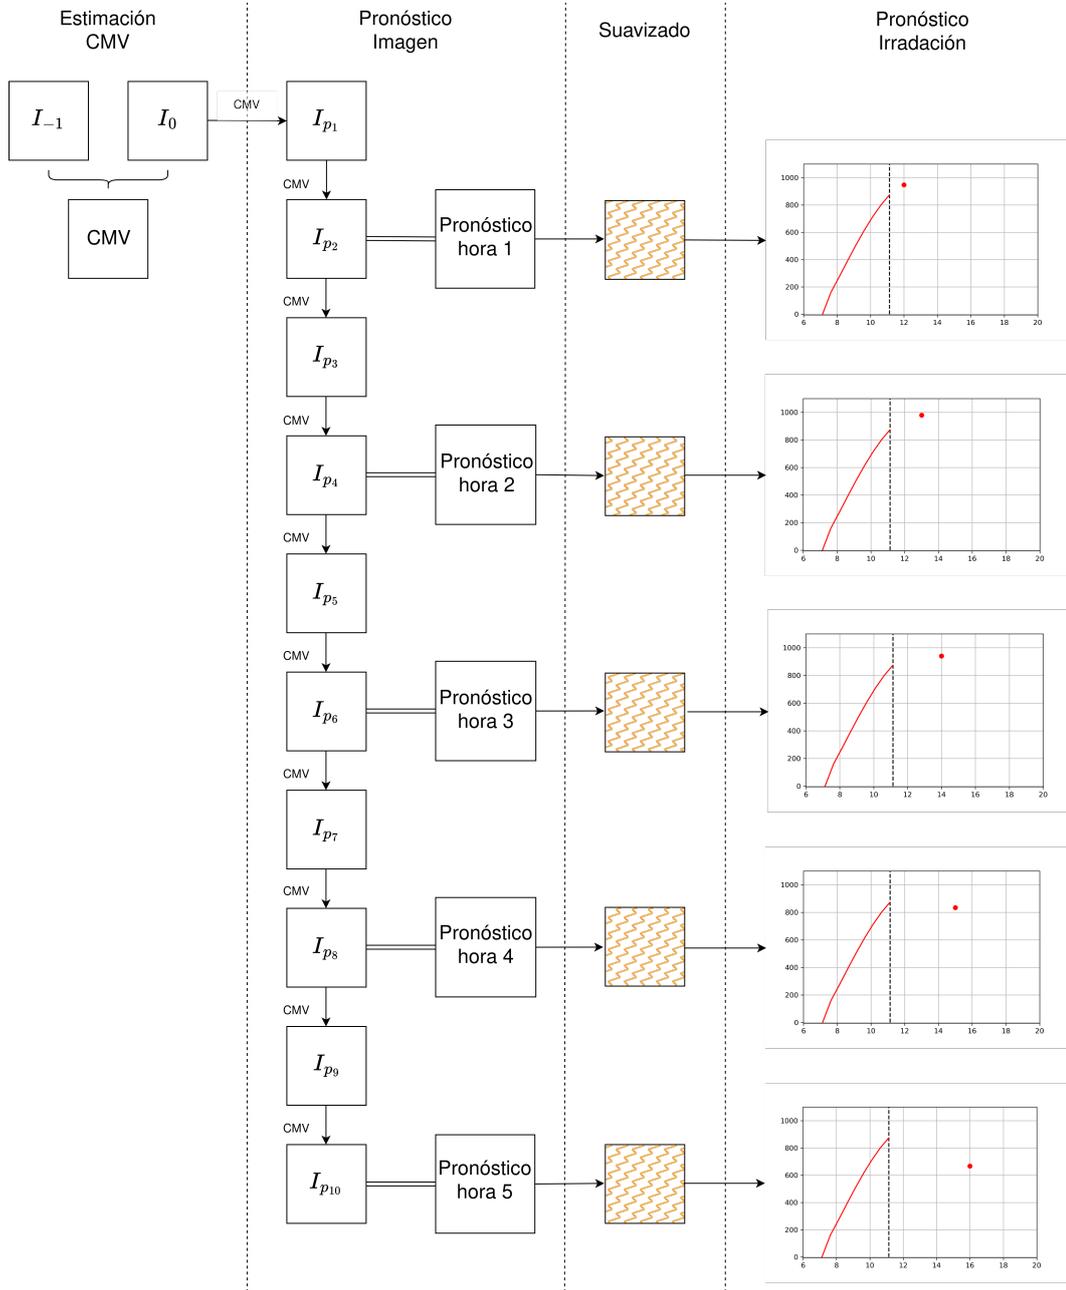


Figura 4.29: Etapas del sistema general, incluyendo la etapa de suavizado.

Capítulo 5

Conclusiones

La predicción de irradiación solar al muy corto plazo (a nivel intra-día) es necesaria para la incorporación de la energía solar fotovoltaica en gran escala a la red eléctrica. La mejor estrategia para este tipo de predicción, al menos en los primeros horizontes de predicción, es la estrategia satelital. Esta técnica se basa en el cálculo de campo de velocidad nuboso (CMV, *Cloud Motion Vectors*) a partir de las últimas dos imágenes satelitales consecutivas. Esto permite anticipar la presencia futura de nubosidad, a partir de la cual se genera una predicción de irradiación solar.

El presente trabajo evaluó diferentes técnicas para la estimación del CMV, considerando la técnica clásica de *block-matching* y cuatro alternativas de flujo óptico, una familia de técnicas de amplio uso en el campo de visión por computadora para la estimación de movimiento en secuencias de video. Este es el primer trabajo a nivel internacional que realiza una comparación de estas técnicas para una misma región y un mismo conjunto de datos satelitales y de medidas en tierra. El trabajo permitió establecer la metodología de estimación de CMV de mejor desempeño, en una comparación justa entre ellas. Además, se analizaron y optimizaron diferentes aspectos de los métodos, tanto para la predicción a nivel de imagen como a nivel de irradiación solar. En virtud de lo anterior, los resultados principales fueron publicados en una revista internacional de prestigio en el área de energía solar (Aicardi et al., 2022). Este manuscrito presenta una versión ampliada de los análisis desarrollados y detalla cada etapa del proceso de pronóstico, analizando elementos que no siempre están en el foco central, como la forma de construir las imágenes pronosticadas.

Se encontró que el método de flujo óptico TVL1 es la mejor estrategia

para el cálculo del CMV en esta región. Este método presentó el mejor desempeño de pronóstico tanto a nivel de imagen como a nivel de irradiación, manteniéndose incluso en los distintos horizontes de pronóstico. También se encontró que el método de menor desempeño es el clásico *block-matching*. Las otras alternativas de flujo óptico analizadas fueron dos variantes del método de [Lucas y Kanade](#), una que considera un valor constante en una región y otra que considera una transformación afín (LK-avg y LK-afn, respectivamente), y el método de [Farnebäck](#). El desempeño del método LK-afn fue mejor que el de LK-avg, por lo que la comparación de desempeño con las demás técnicas consideró sólo el primero. Los principales parámetros de estos métodos fueron optimizados para la región y son brindados en el presente trabajo.

Se comprobó que agregar una etapa de suavizado espacial aplicado a las imágenes pronosticadas mejora el desempeño del pronóstico a nivel de irradiación solar. Esto tiene el doble objetivo de que un promedio espacial de una imagen instantánea represente mejor un valor promedio en la hora de predicción, y el de reducir errores que se acumulan en las predicciones, especialmente para horizontes más lejanos (4-5 horas). En particular, se probó con dos estrategias de suavizado con ventana cuadrada de valores promedio, una de ventana fija de 20 px \times 20 px para toda situación, y otra de ventana óptima calculada para cada horizonte de pronóstico y método. Ambas estrategias mejoran el desempeño de todos los métodos, manteniendo la conclusión sobre el método TVL1. El mejor desempeño se da con estrategias de suavizado con ventanas que van aumentando su tamaño a medida que aumenta el horizonte de pronóstico.

TVL1 es el único método que logra superar a la exigente persistencia convexa en todos los horizontes de pronóstico utilizando suavizado de ventana óptima. También con suavizado de ventana fija este método logra superar a la persistencia convexa para la mayoría de los horizontes de pronóstico. En definitiva, el método TVL1 con suavizado de ventana óptima es la mejor estrategia para el pronóstico de irradiación solar. Este método impone condiciones de suavidad sobre el CMV y permite discontinuidades, lo cual da más “libertad” en el movimiento de los distintos objetos de la imagen (nubes). Este punto es el principal a la hora de explicar por qué este método resulta ser el mejor. El resultado obtenido mejora el desempeño del método clásico *block-matching* y de métodos de referencia exigentes de uso consolidado en el área ([Yang et al., 2020](#)).

Sobre las limitaciones del procedimiento satelital desarrollado en esta tesis, se vio que si bien tiene un desempeño bueno, tiene problemas para predecir comportamientos del recurso muy localizados. El resultado de pronóstico en un sitio cercano al amanecer puede llevar a pronósticos erróneos. Se vio que en ocasiones falta información en la imagen para horas cercanas al amanecer y resulta imposible pronosticar lo que no se ve. Se podría incluir información del infrarrojo como para tener mayor información de lo que no se está viendo con el canal visible y utilizar esa información para mejorar el pronóstico al amanecer. Otra limitación es que sólo se considera una visión 2D de lo que sucede, por lo que el caso de una nube que aparece o desaparece en un tiempo futuro, no es posible de predecir con este procedimiento.

Queda amplio espacio de mejoras en los métodos satelitales. En el presente trabajo sólo fueron optimizados los parámetros principales de los métodos, dejando los demás en su valor por defecto. Estos parámetros son dependientes de la ubicación geográfica, y por tanto de las condiciones climáticas típicas de la región. Se podrían considerar parámetros cuyo valor dependa de características de la imagen derivadas de la nubosidad. En relación al filtro de suavizado, una alternativa es cambiarlo por uno con pesos ponderados, por ejemplo, un filtro gaussiano, que de más importancia a los píxeles próximos a la estación. Otros aspectos de mejora incluyen avanzar en un modelado de la escena que incorpore nociones sobre la dimensión z , posiblemente con la ayuda de otros canales del satélite, o la estimación de un CMV variable en los horizontes de pronóstico.

Otro aspecto a tener en cuenta es cómo afecta un cambio en el tiempo de adquisición de las imágenes. Hoy en día se dispone de imágenes cada 10 minutos con el satélite GOES-16. Esto habilita a estimaciones de los CMV más precisas, debido a que la distancia entre imágenes es menor, y están más cerca de cumplir la restricción de flujo óptico. Un análisis más detallado podría considerar los errores introducidos al considerar la hipótesis de brillo constante como verdadera. Se puede considerar un estudio sobre características de las nubes con estas imágenes de mayor resolución espacial, por ejemplo, un análisis de texturas, patrones, o intermitencias. Finalmente, existe información a priori sobre el movimiento que no se incorpora a estas técnicas. Esto refiere a que visualmente la mayoría de las nubes van de Oeste a Este o vienen desde la dirección Noroeste, siguiendo patrones de circulación atmosférica, y esa información no se está utilizando.

Referencias bibliográficas

- Abal, G., Aicardi, D., Alonso-Suárez, R., y Laguarda, A. (2017). Performance of empirical models for diffuse fraction in Uruguay. *Solar Energy*, 141:166–181.
- Abal, G., Monetta, A., y Alonso-Suárez, R. (2018). Outdoor solar radiometer calibration under ISO-9847:1992 standard and alternative methods. En *2018 IEEE 9th Power, Instrumentation and Measurement Meeting (EPIM)*, pp. 1–6.
- Adelson, E. H., Anderson, C. H., Bergen, J. R., Burt, P. J., y Ogden, J. M. (1984). Pyramid methods in image processing. *RCA engineer*, 29(6):33–41.
- Adrian, R. (1991). Particle-imaging techniques for experimental fluid mechanics. *Annual Review of Fluid Mechanics*, 23(1):261–304.
- Aicardi, D., Musé, P., y Alonso-Suárez, R. (2022). A comparison of satellite cloud motion vectors techniques to forecast intra-day hourly solar global horizontal irradiation. *Solar Energy*, 233:46 – 60.
- Alonso-Suárez, R. (2017). *Estimación del recurso solar en Uruguay mediante imágenes satelitales*. Tesis doctoral, Facultad de Ingeniería, Universidad de la República. Available at: <https://hdl.handle.net/20.500.12008/20200>.
- Alonso-Suárez, R., Abal, G., Musé, P., y Siri, R. (2014). Satellite-derived solar irradiation map for Uruguay. En *Elsevier Energy Procedia*, volumen 57, pp. 1237–1246.
- Alonso-Suárez, R., Abal, G., Siri, R., y Musé, P. (2012). Brightness-dependent tarpley model for global solar radiation estimation using GOES satellite images: application to Uruguay. *Solar Energy*, 86(11):3205–3215.

- Alonso-Suárez, R., Abal, G., Siri, R., Musé, P., y Toscano, P. (2011). Global solar irradiation assessment in Uruguay using Tarpley's model and GOES satellite images. En *Proceedings of ISES Solar World Congress 2011. Vol. Resource Assessment*, pp. 162–173, Kassel, Alemania.
- Alonso-Suárez, R., Dovat, L., Marchesoni, F., Laguarda, A., y Aicardi, D. (2022). Desarrollo y provisión de servicios operativos de irradiancia solar ocurrida y su predicción a corto plazo para plantas PV en Uruguay. Technical report, Fundación Julio Ricaldoni, Facultad de Ingeniería, Universidad de la República.
- Alonso-Suárez, R., Marchesoni, F., y Aicardi, D. (2021). Analysis of persistence-based solar irradiance forecasting benchmarks. En *Proceedings of the ISES Solar World Congress 2021, extended abstract*.
- Casaravilla, G. y Caporale, X. (2022). Propuesta metodológica para la planificación decenal de la expansión de la generación de Uruguay. Reporte Técnico del Grupo de Energía - GEE 3(7):1-13, Facultad de Ingeniería, Universidad de la República.
- Chambolle, A. (2004). An algorithm for total variation minimization and applications. *Journal of Mathematical Imaging and Vision*, 20(1):89–97.
- Chow, C. W., Belongie, S., y Kleissl, J. (2015). Cloud motion and stability estimation for intra-hour solar forecasting. *Solar Energy*, 115:645–655.
- Coimbra, C. F., Kleissl, J., y Marquez, R. (2013). Chapter 8 - overview of solar-forecasting methods and a metric for accuracy evaluation. En Kleissl, J., editor, *Solar Energy Forecasting and Resource Assessment*, pp. 171–194. Academic Press, Boston.
- Cros, S., Sébastien, N., Liandrat, O., y Schmutz, N. (2014). Cloud pattern prediction from geostationary meteorological satellite images for solar energy forecasting. En *Proceedings of SPIE - The International Society for Optical Engineering*, volumen 9242.
- Davies, E. R. (2012). *Computer & Machine Vision - Theory Algorithms Practicalities*. ELSEVIER.

- Diagne, M., David, M., Lauret, P., Boland, J., y Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27:65–76.
- Dise, S., Kankiewicz, A., Schlemmer, J., Hemker, K., Kivalov, S., Hoff, T., y Perez, R. (2013). Operational improvements in the performance of the SUNY satellite-to-solar irradiance model using satellite infrared channels. En *2013 IEEE 39th Photovoltaic Specialists Conference (PVSC)*, pp. 0960–0963.
- Farnebäck, G. (2003). Two-frame motion estimation based on polynomial expansion. En Bigun, J. y Gustavsson, T., editores, *Image Analysis*, pp. 363–370, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Fortun, D., Bouthemy, P., y Kervrann, C. (2015). Optical flow modeling and computation: A survey. *Computer Vision and Image Understanding*, 134:1–21. Image Understanding for Real-world Distributed Video Networks.
- Giacosa, G. (2020). Pronóstico de la energía solar a partir de imágenes satelitales. Tesis de Maestría. Facultad de Ingeniería, Universidad de la República. Available at: <https://hdl.handle.net/20.500.12008/28330>.
- Giacosa, G. y Alonso-Suárez, R. (2020). Performance assessment of intra-day solar irradiation forecast in Uruguay using satellite Cloud Motion Vectors. En *Proceedings of the ISES Solar World Congress 2019 and IEA SHC International Conference on Solar Heating and Cooling for Buildings and Industry 2019*, pp. 2083–2090.
- Gonzalez, R. C. y Woods, R. E. (2014). *Digital Image Processing*. Pearson., third edición.
- Gueymard, C. A. y Ruiz-Arias, J. A. (2016). Extensive worldwide validation and climate sensitivity analysis of direct irradiance predictions from 1-min global irradiance. *Solar Energy*, 128:1–30. Special issue: Progress in Solar Energy.
- Gurín, M., Cornalino, E., Guggeri, A., Alonso-Suárez, R., Giacosa, G., Abal, G., Terra, R., y Chaer, R. (2022). Complementariedad de los recursos renovables (solar–eólico) y su correlación con la demanda de energía eléctrica. Reporte técnico miem-dne 005-2016, Facultad de Ingeniería, Universidad de la República.

- Horn, B. K. P. y Schunck, B. G. (1981). Determining optical flow. *Artif. Intell.*, 17(1-3):185–203.
- IEA (2013). Technology roadmap: Wind energy, 2013 edition. Technical report, International Energy Agency.
- IEA (2014). Technology roadmap: Solar photovoltaic energy, 2014 edition. Technical report, International Energy Agency.
- IEA (2022). World energy outlook 2022, IEA, Paris. Technical report, International Energy Agency.
- Jolliffe, I. T. y Stephenson, D. B. (2011). *Forecast Verification: A Practitioner's Guide in Atmospheric Science*. Wiley and Sons, Inc., Hoboken, New Jersey, second edición.
- Kallio-Myers, V., Riihelä, A., Lahtinen, P., y Lindfors, A. (2020). Global horizontal irradiance forecast for Finland based on geostationary weather satellite data. *Solar Energy*, 198:68–80.
- Kuglin, C. y Hines, D. (1975). The phase correlation image alignment method. En *Proceedings of the IEEE 1975 International Conference on Cybernetics and Society*.
- Kühnert, J., Lorenz, E., y Heinemann, D. (2013). Chapter 11 - satellite-based irradiance and power forecasting for the German energy market. En Kleissl, J., editor, *Solar Energy Forecasting and Resource Assessment*, pp. 267–297. Academic Press, Boston.
- Laguarda, A. (2021). *Modelado de la irradiancia solar sobre la superficie terrestre: Modelos físicos e híbridos utilizando información satelital sobre la Pampa Húmeda*. Tesis doctoral, Facultad de Ingeniería, Universidad de la República. Tesis de Doctorado en Ingeniería de la Energía.
- Laguarda, A. y Abal, G. (2016). Índice de turbidez de Linke a partir de irradiación solar global en Uruguay. *Avances en Energías Renovables y Medio Ambiente*, 20(ISSN 2314-1433):11.35–11.46.
- Laguarda, A., Giacosa, G., Alonso-Suárez, R., y Abal, G. (2020). Performance of the site-adapted CAMS database and locally adjusted cloud index models

- for estimating global solar horizontal irradiation over the Pampa Húmeda region. *Solar Energy*, 199:295–307.
- Lauret, P., Alonso-Suárez, R., Le Gal La Salle, J., y David, M. (2022). Solar forecasts based on the clear sky index or the clearness index: Which is better? *Solar*, 2(4):432–444.
- Lefèvre, M., Oumbe, A., Blanc, P., Espinar, B., Qu, Z., Wald, L., Homscheidt, M. S., y Arola, A. (2013). McClear: a new model estimating downwelling solar radiation at ground level in clear-sky conditions. *Atmospheric Measurement Techniques, European Geosciences Union*, 6:2403–2418.
- Lorenz, E., Hammer, A., y Heinemann, D. (2004). Short term forecasting of solar radiation based on satellite data. En *EUROSUN2004 (ISES Europe Solar Congress)*, pp. 841–848.
- Lorenz, E., Hurka, J., Heinemann, D., y Beyer, H. G. (2009). Irradiance forecasting for the power prediction of grid-connected photovoltaic systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2(1):2–10.
- Lucas, B. D. y Kanade, T. (1981). An iterative image registration technique with an application to stereo vision. En *Proceedings of the 7th International Joint Conference on Artificial Intelligence - Volume 2, IJCAI'81*, pp. 674–679, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Mathiesen, P. y Kleissl, J. (2011). Evaluation of numerical weather prediction for intra-day solar forecasting in the continental united states. *Solar Energy*, 85(5):967–977.
- McArthur, L. (2005). Baseline Surface Radiation Network (BSRN) Operations Manual. Td-no. 1274, wrcp/wmo, World Meteorological Organization (WMO). www.wmo.org.
- McMahan, A. C., Grover, C. N., y Vignola, F. E. (2013). Chapter 4 - evaluation of resource risk in solar-project financing. En Kleissl, J., editor, *Solar Energy Forecasting and Resource Assessment*, pp. 81–95. Academic Press, Boston.
- Meinhardt-Llopis, E., Sánchez Pérez, J., y Kondermann, D. (2013). Horn-Schunck Optical Flow with a Multi-Scale Strategy. *Image Processing On Line*, 3:151–172. <https://doi.org/10.5201/ipol.2013.20>.

- Nonnenmacher, L. y Coimbra, C. F. (2014). Streamline-based method for intra-day solar forecasting through remote sensing. *Solar Energy*, 108:447–459.
- OPP (2019). Hacia una estrategia nacional de desarrollo, uruguay 2050: Presente y futuro de las energías renovables en uruguay. Technical report, Oficina de planeamiento y presupuesto.
- Peel, M. C., Finlayson, B. L., y McMahon, T. A. (2007). Updated world map of the köppen-geiger climate classification. *Hydrology and Earth System Sciences Discussions*, 11:1633–1644.
- Peng, Z., Yoo, S., Yu, D., y Huang, D. (2013). Solar irradiance forecast system based on geostationary satellite. En *2013 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, pp. 708–713.
- Perez, R., Cebecauer, T., y Šúri, M. (2013a). Chapter 2 - semi-empirical satellite models. En Kleissl, J., editor, *Solar Energy Forecasting and Resource Assessment*, pp. 21–48. Academic Press, Boston.
- Perez, R. y Hoff, T. E. (2013). Chapter 10 - SolarAnywhere forecasting. En Kleissl, J., editor, *Solar Energy Forecasting and Resource Assessment*, pp. 233–265. Academic Press, Boston.
- Perez, R., Ineichen, P., Moore, K., Kmieciak, M., Chain, C., George, R., y Vignola, F. (2002). A new operational model for satellite-derived irradiances: description and validation. *Solar Energy*, 73(5):307–317.
- Perez, R., Lorenz, E., Pelland, S., Beauharnois, M., Van Knowe, G., Hemker, K., Heinemann, D., Remund, J., Müller, S. C., Traunmüller, W., Steinmauer, G., Pozo, D., Ruiz-Arias, J. A., Lara-Fanego, V., Ramirez-Santigosa, L., Gaston-Romero, M., y Pomares, L. M. (2013b). Comparison of numerical weather prediction solar irradiance forecasts in the us, canada and europe. *Solar Energy*, 94:305–326.
- Piccioli, I., Laguarda, A., y Abal, G. (2018). Transporte de irradiación global horizontal a una superficie inclinada: efecto de la separación directa-difusa. En *Anales del XVI Congreso Ibérico y XII Congreso Iberoamericano de Energía Solar, Asociación Española de Energía Solar*, pp. 1–8.

- PVPS, I. (2022). Iea pvps annual report. Technical report, International Energy Agency Photovoltaic Power Systems Programme.
- Qu, Z., Oumbe, A., Blanc, P., Espinar, B., Gesell, G., Gschwind, B., Klüser, L., Lefèvre, M., Saboret, L., Schroedter-Homscheidt, M., y Wald, L. (2017). Fast radiative transfer parameterisation for assessing the surface solar irradiance: The Heliosat-4 method. *Meteorologische Zeitschrift*, 26(1):33–57.
- Rigollier, C., Bauer, O., y Wald, L. (2000). On the clear sky model of the ESRA –European Solar Radiation Atlas– with respect to the Heliosat method. *Solar Energy*, 68(1):33–48.
- Rigollier, C., Lefevre, M., y Wald, L. (2004). The method Heliosat-2 for deriving shortwave solar radiation from satellite images. *Solar Energy*, 77(2):159–169.
- Roy, A., Hammer, A., Heinemann, D., Lünsdorf, O., y Lezaca, J. (2022). Impact of tropical convective conditions on solar irradiance forecasting based on cloud motion vectors. *Environmental Research Letters*, 17(10):104048.
- Rudin, L. I., Osher, S., y Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 60(1):259–268.
- Salio, P., Nicolini, M., y Zipser, E. J. (01 Apr. 2007). Mesoscale convective systems over southeastern south america and their relationship with the south american low-level jet. *Monthly Weather Review*, 135(4):1290–1309.
- Sengupta, M., Xie, Y., Lopez, A., Habte, A., Maclaurin, G., y Shelby, J. (2018). The National Solar Radiation Data Base (NSRDB). *Renewable and Sustainable Energy Reviews*, 89:51–60.
- Ssekulima, E. B., Anwar, M. B., Al Hinai, A., y El Moursi, M. S. (2016). Wind speed and solar irradiance forecasting techniques for enhanced renewable energy integration with the grid: a review. *IET Renewable Power Generation*, 10(7):885–989.
- Sánchez, J., Meinhardt-Llopis, E., y Facciolo, G. (2013). TV-L1 optical flow estimation. *Image Processing Online (IPOL)*.

- Teixeira-Branco, V. (2023). Evaluación de modelos numéricos globales para la predicción de la radiación solar global en el sureste de Sudamérica. Tesis de Maestría. Facultad de Ingeniería, Universidad de la República.
- Teixeira-Branco, V., Alonso-Suárez, R., y Cazes, G. (2022). Pronóstico del día siguiente de la radiación solar en la región de la Pampa Húmeda: análisis de desempeño del modelo GFS. *Revista Brasileira de Energia Solar*, 13(1):11–19.
- Teixeira-Branco, V., Alonso-Suárez, R., y David, M. (2021). Performance assessment of the ECMWF solar irradiation forecast in the Pampa Húmeda region of South America. En *Proceedings of the ISES Solar World Congress 2021*.
- Urbich, I., Bendix, J., y Müller, R. (2019). The seamless solar radiation (sensor) forecast for solar surface irradiance—method and validation. *Remote Sensing*, 11(21).
- Wang, W., Yang, D., Hong, T., y Kleissl, J. (2022). An archived dataset from the ecmwf ensemble prediction system for probabilistic solar power forecasting. *Solar Energy*, 248:64–75.
- Wedel, A. y Cremers, D. (2011). *Stereo Scene Flow for 3D Motion Analysis*. Springer.
- Wu, Q., Wang, H.-Q., Lin, Y.-J., Zhuang, Y.-Z., y Zhang, Y. (2016). Deriving amvs from geostationary satellite images using optical flow algorithm based on polynomial expansion. *Journal of Atmospheric and Oceanic Technology*, 33(8):1727 – 1747.
- Wu, X. y Sun, F. (2005). Post-launch calibration of GOES imager visible channel using MODIS. En *Proc. SPIE*, volumen 5882.
- Yang, D. (2016). Solar radiation on inclined surfaces: Corrections and benchmarks. *Solar Energy*, 136:288–302.
- Yang, D. (2019). Making reference solar forecasts with climatology, persistence, and their optimal convex combination. *Solar Energy*, 193:981–985.
- Yang, D., Alessandrini, S., Antonanzas, J., Antonanzas-Torres, F., Badescu, V., Beyer, H. G., Blaga, R., Boland, J., Bright, J. M., Coimbra, C. F., David,

- M., Âzeddine Frimane, Gueymard, C. A., Hong, T., Kay, M. J., Killinger, S., Kleissl, J., Lauret, P., Lorenz, E., van der Meer, D., Paulescu, M., Perez, R., Perpiñán-Lamigueiro, O., Peters, I. M., Reikard, G., Renné, D., Saint-Drenan, Y.-M., Shuai, Y., Urraca, R., Verbois, H., Vignola, F., Voyant, C., y Zhang, J. (2020). Verification of deterministic solar forecasts. *Solar Energy*, 210:20–37. Special Issue on Grid Integration.
- Yang, D., Wang, W., Bright, J. M., Voyant, C., Notton, G., Zhang, G., y Lyu, C. (2022a). Verifying operational intra-day solar forecasts from ecmwf and noaa. *Solar Energy*, 236:743–755.
- Yang, D., Wang, W., Gueymard, C. A., Hong, T., Kleissl, J., Huang, J., Perez, M. J., Perez, R., Bright, J. M., Xia, X., van der Meer, D., y Peters, I. M. (2022b). A review of solar forecasting, its dependence on atmospheric sciences and implications for grid integration: Towards carbon neutrality. *Renewable and Sustainable Energy Reviews*, 161:112348.
- Zach, C., Pock, T., y Bischof, H. (2007). A duality based approach for realtime TV-L1 optical flow. En *Proceedings of the 29th DAGM Conference on Pattern Recognition*, pp. 214–223, Berlin, Heidelberg. Springer-Verlag.

Glosario

Altura solar (α_s)	Ángulo que forma la línea Tierra-Sol con el plano horizontal. Es el complemento del Ángulo cenital (θ_z).
Ángulo cenital (θ_z)	Ángulo entre la dirección del Sol y la vertical local (cenit local).
CMV - CMF	<i>Cloud Motion Vector - Cloud Motion Field</i> , refiere al campo de vectores asociado con el movimiento de las nubes.
DL	Estrategia de extrapolación que recorre la imagen destino asignando a cada pixel un valor en base a valores de la imagen origen utilizando interpolación bilineal.
DN	Estrategia de extrapolación que recorre la imagen destino asignando a cada pixel un valor en base a valores de la imagen origen utilizando vecino más cercano.
ESRA (modelo)	Modelo de estimación analítica desarrollado por <i>European Solar Radiation Atlas</i> para estimar la irradiación en todo tipo de cielo. En el presente trabajo se utiliza para conocer la irradiación en condiciones de cielo claro ya que sólo necesita un parámetro de entrada (T_L : Turbidez de Linke).
Estrategia piramidal	Proceso iterativo para lidiar con desplazamientos grandes entre imágenes consecutivas. En el presente trabajo es utilizado en todos los métodos de OF.
Flujo Óptico (OF)	Método que evalúa los cambios entre dos imágenes consecutivas y es muy utilizado en el campo de la visión por computadora. La hipótesis principal del OF es la hipótesis de brillo constante en desplazamientos infinitesimales.
FRB	Método Farneback para la estimación del CMV.

FS		<i>Forecasting Skill</i> - Habilidad del pronóstico. Mide el desempeño de un pronóstico respecto a un pronóstico de referencia (persistencia).
		$FS = 1 - \frac{RMSD_{prono}}{RMSD_{pers}}$
GHI		<i>Global Horizontal Irradiation</i> , irradiación global sobre plano horizontal.
HS		Método variacional para la estimación del CMV - Horn-Schunck.
Horizonte de pronóstico	de	Qué tan a futuro se hace el pronóstico.
Índice de cielo claro (k_c)		Se define como el cociente entre la irradiación global sobre plano horizontal (GHI) y la irradiación que se tendría en caso de condiciones de cielo claro (sin nubosidad). Es una cantidad adimensionada y sin variación geométrica cuyas fluctuaciones representan variaciones en la nubosidad del cielo.
LES		Laboratorio de Energía Solar - les.edu.uy
LK-afn		Método Lukas-Kanade para la estimación del CMV. Se considera una relación afín entre bloques de imágenes consecutivas.
LK-avg		Método Lukas-Kanade para la estimación del CMV. Se considera un desplazamiento uniforme entre bloques de imágenes consecutivas.
MBD		Desviación media entre valor estimado (Y_{est}) y observado (Y_{obs}).
		$MBD = \frac{1}{N} \sum_{i=1}^N (Y_{est} - Y_{obs})$
OpenCV		Biblioteca Python para visión por computadora.

OW	Estrategia de extrapolación que recorre la imagen origen trasladando bloques a la imagen destino de acuerdo al promedio de desplazamiento del bloque. Se promedian bloques solapados y se realiza <i>inpaint</i> sobre los faltantes.
PIV	Método block-matching adaptado de la biblioteca openPIV de Python para la estimación del CMV.
RMSD	Desviación cuadrática media entre valor estimado (Y_{est}) y observado (Y_{obs}).
	$RMSD = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{est} - Y_{obs})^2}$
Turbidez de Linke (T_L)	Es un parámetro de caracterización de la atmósfera en cielo claro y representa el número de atmósferas limpias y secas que tiene que atravesar un haz de irradiación solar para obtener la atenuación real observada. $T_L(m = 2)$ refiere al T_L para una masa de aire igual a 2 y es el que utiliza el modelo ESRA.
TVL1	Método variacional para la estimación del CMV.

APÉNDICES

Apéndice A

Modelo de cielo claro ESRA

Un modelo de cielo claro permite estimar la irradiación superficial en ausencia de nubes. El modelo ESRA es un modelo de cielo claro basado en un único parámetro: la Turbidez de Linke (T_L). Se modelan las componentes de irradiación directa normal (G_b) y difusa en plano horizontal (G_d), y luego se suman según Ec. A.1 para obtener la irradiación global sobre plano horizontal en cielo claro.

$$GHI_{cs} = G_b \times \cos\theta_z + G_d \quad (\text{A.1})$$

La Turbidez de Linke es un parámetro de caracterización de la atmósfera en cielo claro y representa el número de atmósferas limpias y secas que tiene que atravesar un haz de irradiación solar para obtener la atenuación real observada. $T_L(m = 2)$ refiere al T_L para una masa de aire igual a 2 y es el que utiliza el modelo ESRA. T_L tiene un comportamiento estacional por lo que debe considerarse un parámetro diario o mensual para mejor ajuste con los datos de tierra.

La irradiación directa en incidencia normal (G_b), se calcula como (Ec. A.2).

$$G_b = G_s \times e^{-m \times \delta_R(m) \times T_L} \quad (\text{A.2})$$

Donde, $m \approx \frac{1}{\cos\theta_z}$ y $\delta_R(m)$ es la profundidad óptica de una atmósfera limpia y seca. Es importante tener en cuenta que el parámetro m tiende a diverger en el amanecer y el atardecer y por lo tanto tiende a introducir más errores cerca de esos momentos del día.

La irradiación difusa en plano horizontal (G_d), se calcula como (Ec. A.3).

$$G_d = G_s \times F_n \times T_z(\hat{T}_L) \times F_d(\theta_z, \hat{T}_L) \quad (\text{A.3})$$

Aquí el \hat{T}_L refiere al T_L utilizado en el artículo original ([Rigollier et al. \(2000\)](#)), pero que difiere del TL utilizado en la actualidad, que es $\hat{T}_L = T_L/0.8665$. T_z es una relación cuadrática en \hat{T}_L , y F_d es una relación cuadrática en $\cos\theta_z$ con parámetros dependientes de \hat{T}_L

Apéndice B

Solución del método HS

En el artículo original [Horn y Schunck \(1981\)](#) el parámetro de trade-off (α) está al cuadrado (aquí, α^2), y como no cambia el resultado de la Ec. 2.19, se resolverá el original de la Ec. B.1.

$$\arg \min_{u,v} \left\{ \int_I \alpha^2 \cdot ((\nabla u)^2 + (\nabla v)^2) + (I_x \cdot u + I_y \cdot v + I_t)^2 \right\} \quad (\text{B.1})$$

Para hallar el par (u, v) que minimiza la Ec. B.1, es necesario derivar respecto a u y a v para obtener así dos ecuaciones que permitan resolver el CMV.

Derivando respecto a u :

$$I_x^2 \cdot u + I_x \cdot I_y \cdot v = \alpha^2 \cdot \nabla^2 u - I_x \cdot I_t \quad (\text{B.2})$$

Derivando respecto a v :

$$I_x \cdot I_y \cdot u + I_y^2 \cdot v = \alpha^2 \cdot \nabla^2 v - I_x \cdot I_t \quad (\text{B.3})$$

Se realiza la aproximación $\nabla^2 w \approx \bar{w} - w$, donde w indica el valor en un píxel y \bar{w} es el promedio considerando a los vecinos. Sustituyendo y agrupando, se obtienen B.4 y B.5:

$$(I_x^2 + \alpha^2) \cdot u + I_x \cdot I_y \cdot v = \alpha^2 \cdot \bar{u} - I_x \cdot I_t \quad (\text{B.4})$$

$$I_x \cdot I_y \cdot u + (I_y^2 + \alpha^2) \cdot v = \alpha^2 \cdot \bar{v} - I_y \cdot I_t \quad (\text{B.5})$$

Resolviendo en u y v :

$$(I_x^2 + I_y^2 + \alpha^2) \cdot u = (I_y^2 + \alpha^2) \cdot \bar{u} - I_x \cdot I_y \cdot \bar{v} - I_x \cdot I_t \quad (\text{B.6})$$

$$(I_x^2 + I_y^2 + \alpha^2) \cdot v = -I_x \cdot I_y \cdot \bar{u} + (I_x^2 + \alpha^2) \cdot \bar{v} - I_y \cdot I_t \quad (\text{B.7})$$

O, escrito de otra forma:

$$(I_x^2 + I_y^2 + \alpha^2) \cdot (u - \bar{u}) = -I_x \cdot (I_x \cdot \bar{u} + I_y \cdot \bar{v} + I_t) \quad (\text{B.8})$$

$$(I_x^2 + I_y^2 + \alpha^2) \cdot (v - \bar{v}) = -I_y \cdot (I_x \cdot \bar{u} + I_y \cdot \bar{v} + I_t) \quad (\text{B.9})$$

Finalmente, aplicando Gauss-Siedel, se puede plantear de forma iterativa:

$$(u_{(k+1)}, v_{(k+1)}) = \left(u_k - I_x \cdot \frac{I_x \cdot u_k + I_y \cdot v_k + I_t}{I_x^2 + I_y^2 + \alpha^2}, v_k - I_y \cdot \frac{I_x \cdot u_k + I_y \cdot v_k + I_t}{I_x^2 + I_y^2 + \alpha^2} \right) \quad (\text{B.10})$$

De esta forma, se tiene una solución iterativa al problema planteado en el cual se modifica, en cada paso, el resultado anterior.

Apéndice C

Solución del método TVL1

La Ec. 2.2 se puede escribir como la Ec. C.1, donde $z = (x, y)$ y $w = (u, v)$. Esta ecuación tiene un término no lineal y se puede linealizar aplicando series de Taylor con $\hat{w} \approx w$, como en la Ec. C.2.

$$I(z + w) = I(z) \quad (\text{C.1})$$

$$I(z + w) \approx \nabla I(z + \hat{w}) \cdot (z - \hat{w}) + I(z + \hat{w}); \text{ Con } \hat{w} \approx w \quad (\text{C.2})$$

Se plantea la minimización de la Ec. 2.20 respecto a u y v . Por practicidad, se define $\rho(w)$ (Ec. C.3) como el término asociado al brillo constante, por lo tanto la Ec. 2.20 se puede reescribir como la Ec. C.4.

$$I(z + w) - I(z) \approx \nabla I(z + \hat{w}) \cdot (w - \hat{w}) + I(z + \hat{w}) - I(z) = \rho(w) \quad (\text{C.3})$$

$$E(w) = \int_{\Omega} |\nabla u| + |\nabla v| + \lambda |\rho(w)| \quad (\text{C.4})$$

Para hallar el mínimo de $E(w)$ de forma eficiente se agrega un término de relajación, según la Ec. C.5.

$$E_{\theta}(w, q) = \int_{\Omega} |\nabla u| + |\nabla v| + \frac{1}{2\theta} |w - q|^2 + \lambda |\rho(q)| \quad (\text{C.5})$$

De esta forma, si θ es lo suficientemente pequeño se está obligando a que $w \approx q$ y se vuelve a la Ec. C.4. Este planteo lleva a una forma de resolución más práctica fijando alternadamente w y q , y resolviendo la restante. Fijando

q , se debe resolver la Ec. C.6, y fijando w , se debe resolver la Ec. C.7.

$$\min_w \int_{\Omega} |\nabla u| + |\nabla v| + \frac{1}{2\theta} |w - q|^2 \quad (\text{C.6})$$

$$\min_q \int_{\Omega} \frac{1}{2\theta} |w - q|^2 + \lambda |\rho(q)| \quad (\text{C.7})$$

La Ec. C.6 es un problema de *denoising* (filtrado de ruido) planteado en Rudin et al. (1992) y se puede resolver con el algoritmo de Chambolle (2004), quien también demuestra condiciones que aseguran la convergencia.

$$p_i^{k+1} := \frac{p_i^k + \frac{\tau}{\theta} \nabla(q_i^{k+1} + \theta \operatorname{div}(p_i^k))}{1 + \left| \frac{\tau}{\theta} \nabla(q_i^{k+1} + \theta \operatorname{div}(p_i^k)) \right|} \quad (\text{C.8})$$

La solución es la que se muestra en la Ec. C.8. En este caso $i \in \{1, 2\}$, ya que $p \in \mathbb{R}^2$. La solución para w se muestra en la Ec. C.9.

$$w_i^{k+1} := q_i^{k+1} + \theta \operatorname{div}(p_i^k) \quad (\text{C.9})$$

La Ec. C.7 se puede resolver con la Ec. C.10, donde se define un umbral cuya función se detalla en la Ec. C.11. La demostración del umbral puede encontrarse en la siguiente sección.

$$q^{k+1} := w^{k+1} + TH(w^{k+1}, \hat{w}) \quad (\text{C.10})$$

$$TH(w^{k+1}, \hat{w}) = \begin{cases} \lambda \theta \nabla I(z + \hat{w}) & ; \rho(w, \hat{w}) < -\lambda \theta |\nabla I(z + \hat{w})|^2 \\ -\lambda \theta \nabla I(z + \hat{w}) & ; \rho(w, \hat{w}) > \lambda \theta |\nabla I(z + \hat{w})|^2 \\ -\rho(w, \hat{w}) \frac{\nabla I(z + \hat{w})}{|\nabla I(z + \hat{w})|^2} & ; |\rho(w, \hat{w})| \leq \lambda \theta |\nabla I(z + \hat{w})|^2 \end{cases} \quad (\text{C.11})$$

Cálculo del umbral

La Ec. C.7 se puede resolver derivando respecto a q e igualando a cero. Para esto se introduce una perturbación ∂q (Ec. C.12).

$$\lim_{\partial q \rightarrow 0} \frac{1}{\partial q} \left[\int_{\Omega} \frac{1}{2\theta} |w - (q + \partial q)|^2 + \lambda |\rho(q + \partial q)| - \int_{\Omega} \frac{1}{2\theta} |w - q|^2 + \lambda |\rho(q)| \right] = 0 \quad (\text{C.12})$$

Se diferencian tres casos; $\rho(q) > 0$, $\rho(q) < 0$ y $\rho(q) = 0$.

Caso $\rho(q) > 0$:

$$\begin{aligned}
& \lim_{\partial q \rightarrow 0} \frac{1}{\partial q} \left[\int_{\Omega} \frac{1}{2\theta} \left((w-q)^2 - \partial q^2 - 2(w-q)\partial q - (w-q)^2 \right) + \lambda \left(\rho(q+\partial q) - \rho(q) \right) \right] = \\
& \lim_{\partial q \rightarrow 0} \frac{1}{\partial q} \left[\int_{\Omega} \frac{1}{2\theta} \left(-\partial q^2 - 2(w-q)\partial q \right) + \lambda \left(\rho(q+\partial q) - \rho(q) \right) \right] = \\
& \lim_{\partial q \rightarrow 0} \left[\int_{\Omega} \frac{1}{2\theta} \left(-\partial q - 2(w-q) \right) + \lambda \left(\frac{\rho(q+\partial q) - \rho(q)}{\partial q} \right) \right] = \int_{\Omega} \frac{1}{2\theta} \left(-2(w-q) \right) + \lambda \rho'(q) = 0
\end{aligned} \tag{C.13}$$

Como el intervalo de integración es independiente del integrando, éste debe ser cero (Ec. C.14).

$$\frac{1}{2\theta} \left(-2(w-q) \right) + \lambda \rho'(q) = 0 \tag{C.14}$$

Partiendo de la definición de ρ ; $\rho(q) = \nabla I(z + \hat{w})(q - \hat{w}) + I(z + \hat{w}) - I(z)$, se llega a la Ec. C.15.

$$\rho'(q) = \nabla I(z + \hat{w}) \tag{C.15}$$

De las Ecs. (C.14) y (C.15), se obtiene la Ec. C.16.

$$q = w - \lambda\theta \cdot \nabla I(z + \hat{w}) \tag{C.16}$$

Como $\rho(q) > 0$, se concluyen las Ecs. C.17 y C.18.

$$\rho(q) = \nabla I(z + \hat{w})(q - \hat{w}) + I(z + \hat{w}) - I(z) = \nabla I(z + \hat{w}) \cdot \lambda\theta \cdot \nabla I(z + \hat{w}) + \rho(w) > 0 \tag{C.17}$$

$$\begin{aligned}
q - w &= -\lambda\theta \cdot \nabla I(z + \hat{w}) \\
\rho(w) &> \lambda\theta \cdot (\nabla I(z + \hat{w}))^2
\end{aligned} \tag{C.18}$$

Caso $\rho(q) < 0$: Se utiliza el mismo razonamiento que para el caso $\rho(q) > 0$, y se llega al resultado se muestra en la Ec. C.19.

$$\begin{aligned}
q - w &= \lambda\theta \cdot \nabla I(z + \hat{w}) \\
\rho(w) &< -\lambda\theta \cdot (\nabla I(z + \hat{w}))^2
\end{aligned} \tag{C.19}$$

Caso $\rho(q) = 0$:

$$\begin{aligned}\rho(q) &= \nabla I(z + \hat{w})(q - \hat{w}) + I(z + \hat{w}) - I(z) = 0 \\ q &= w + \Delta\end{aligned}\tag{C.20}$$

Combinando las Ecs. C.20, se obtienen las Ecs. C.21.

$$\begin{aligned}\rho(q) &= \rho(w) + \Delta \cdot \nabla I(z + \hat{w}) = 0 \\ \Delta &= \frac{-\rho(w)}{\nabla I} = \frac{-\rho(w) \cdot \nabla I}{|\nabla I|^2} \\ q - w &= \frac{-\rho(w) \cdot \nabla I}{|\nabla I|^2} \\ |\rho(w)| &\leq \lambda \theta \cdot (\nabla I(z + \hat{w}))^2\end{aligned}\tag{C.21}$$

De las Ecs. C.18, C.19 y C.21, se obtiene el umbral mostrado en la Ec. C.11.

Apéndice D

Suavizado a nivel de imagen

En la Figura D.1 se muestran los resultados de optimización de ventana de suavizado para cada método. Para el método TVL1, el resultado fue mostrado en Figura 4.8.

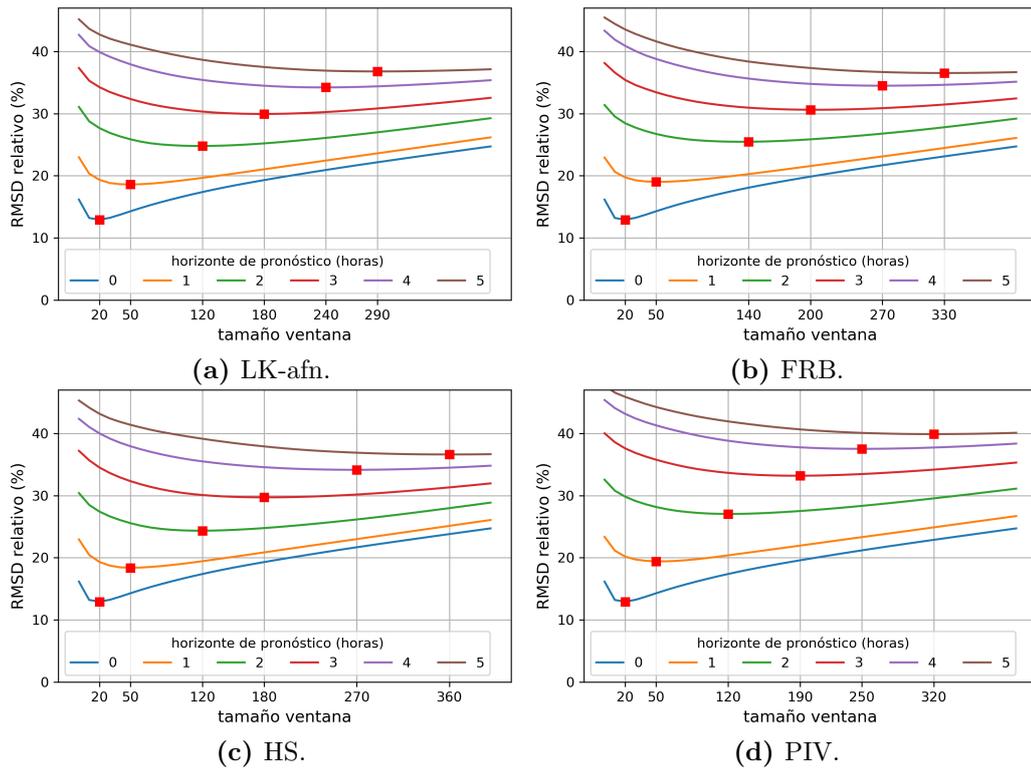


Figura D.1: Suavizado a nivel de imagen y su efecto a nivel de irradiación con la métrica RMSD relativo para cada método.

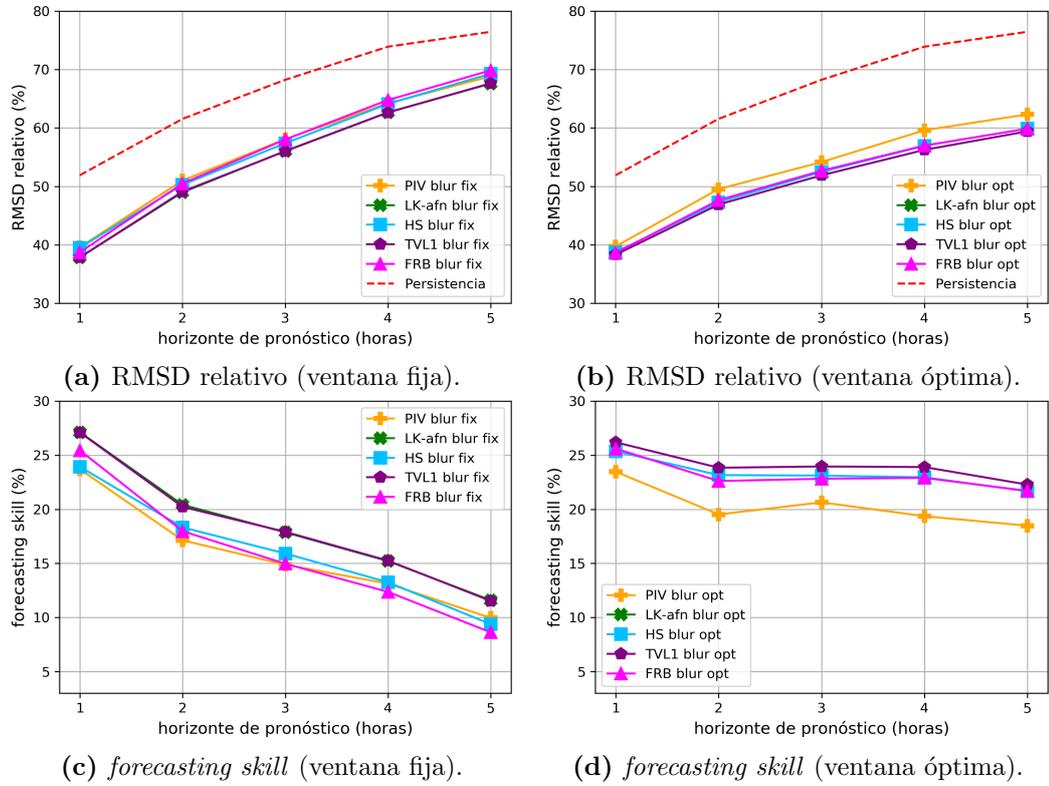


Figura D.2: Desempeño a nivel de imagen de los métodos en función del tipo de suavizado.

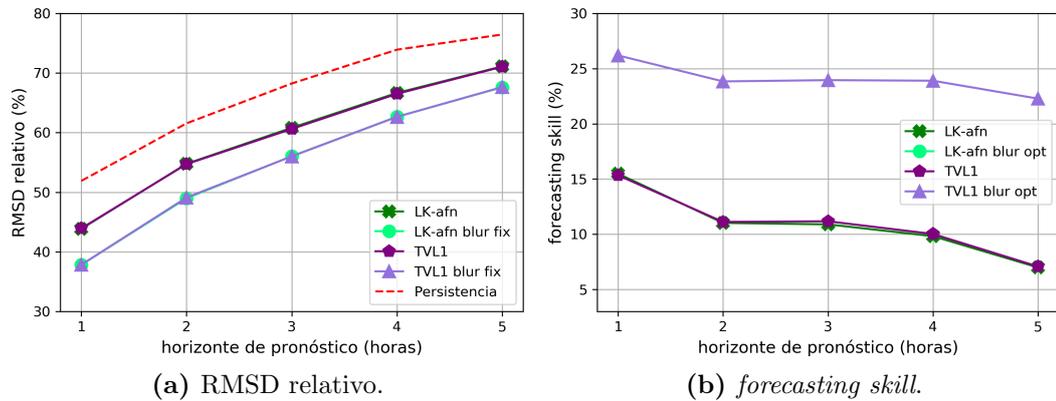


Figura D.3: Desempeño a nivel de imagen para los casos sin y con suavizado considerando los mejores dos métodos (TVL1 y LK-afn).