

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

FACULTAD DE CIENCIAS



**“PRONÓSTICO DE TIEMPO SEVERO A MUY CORTO PLAZO
(NOWCASTING) USANDO DATOS DEL SATÉLITE GOES-16**

Trabajo de Suficiencia Profesional para Optar el Título de:

INGENIERO METEORÓLOGO

JOAO HENRY HUAMÁN CHINCHAY

Lima – Perú

2024

La UNALM es la titular de los derechos patrimoniales de la presente investigación
(Art. 24. Reglamento de Propiedad Intelectual)

PRONÓSTICO DE TIEMPO SEVERO A MUY CORTO PLAZO (NOWCASTING) USANDO DATOS DEL SATÉLITE GOES-16

INFORME DE ORIGINALIDAD

10%	9%	2%	2%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	2%
2	sedici.unlp.edu.ar Fuente de Internet	1%
3	orcid.org Fuente de Internet	1%
4	mtc-m21c.sid.inpe.br Fuente de Internet	<1%
5	www2.senamhi.gob.pe Fuente de Internet	<1%
6	Submitted to Universidad Nacional Agraria La Molina Trabajo del estudiante	<1%
7	www.uncuyo.edu.ar Fuente de Internet	<1%
8	www.upo.es Fuente de Internet	<1%

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

FACULTAD DE CIENCIAS

**“PRONÓSTICO DE TIEMPO SEVERO A MUY CORTO PLAZO
(NOWCASTING) USANDO DATOS DEL SATÉLITE GOES-16”**

Trabajo de Suficiencia Profesional para Optar el Título Profesional de:

INGENIERO METEORÓLOGO

Presentado por:

JOAO HENRY HUAMÁN CHINCHAY

Sustentada y aprobado por el siguiente jurado:

Mg. Sc. Victoria Doris Calle Montes
PRESIDENTE

Dr. Alexis Nicolás Ibáñez Blancas
MIEMBRO

Mg. Sc. Franklin Delio Unsihuay Tovar
MIEMBRO

Mg. Sc. Edison Cholán Rodríguez
ASESOR

DEDICATORIA

A mis padres Juan Santiago Huamán Huamán y Amelia Chinchay Barrientos, a mis hermanas Yuriko y Ailine, a mi sobrino Thiago, a mi abuela Maura Barrientos Bautista y a la memoria de mi abuelo Mariano Chinchay Suica, por su amor y apoyo incondicional.

AGRADECIMIENTOS

A Dios, por cuidar de mí en todo momento y ayudarme a alcanzar mis objetivos.

A mi familia por su apoyo en todo momento.

A mi asesor Edison Cholan por su apoyo, su amistad y la confianza depositada en mí.

A Kelita Quispe, directora de la Subdirección de Predicción Meteorológica, por sus recomendaciones y su apoyo en la elaboración de este trabajo.

Al Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) por permitirme presentar esta investigación para la obtención de mi título profesional.

ÍNDICE GENERAL

RESUMEN.....	iv
ABSTRACT	v
I. INTRODUCCIÓN	1
1.1 Problemática	1
1.2 Objetivos.....	3
1.2.1 Objetivo General	3
1.2.2 Objetivos Específicos	3
II. REVISIÓN DE LITERATURA	4
2.1 GOES-16	4
2.1.1 ABI.....	5
2.1.2 GLM	6
2.2 Atributos Físicos de las Nubes	7
2.3 ForTraCC.....	9
III. DESARROLLO DEL TRABAJO	11
3.1 Área de Estudio y Datos.....	11
3.2 Metodología.....	13
3.2.1 Identificación de Nubes Convectivas	13
3.2.2 Identificación de Clusters a Través del Tiempo.....	13
3.2.2 Extracción de Información de los Clusters	16
3.2.3 Evaluación de Severidad.....	18
3.2.4 Estimación de la Posición de los Clusters	20
3.2.5 Conversión de Severidad a Precipitación	21
3.2.6 Pronóstico a Muy Corto Plazo	23
3.2.7 Validación de Resultados	25
IV. RESULTADOS Y DISCUSIONES.....	28
V. CONCLUSIONES	31
VI. RECOMENDACIONES	32
VII. REFERENCIAS BIBLIOGRÁFICAS.....	33

ÍNDICE DE TABLAS

Tabla 1: Niveles de procesamiento de los datos del GOES-16.....	4
Tabla 2: Descripción de las bandas del ABI	5
Tabla 3: Fechas y horarios de los datos de satélite usadas en la validación	12
Tabla 4: Criterios para la numeración y denominación de los clusters	15
Tabla 5: Niveles de severidad basados en la variación de la temperatura de brillo	19
Tabla 6: Niveles de severidad basados en la máxima densidad de flash en 10 minutos	19
Tabla 7: Tabla de severidad total y su interpretación	20
Tabla 8: Resultados de la evaluación del algoritmo para identificar lluvias.....	28
Tabla 9: Resultados de la evaluación del algoritmo para identificar lluvias severas	28

ÍNDICE DE FIGURAS

Figura 1. Región de observación del GLM (región en azul).....	6
Figura 2. Representación gráfica de los productos del GLM.....	7
Figura 3. Pronósticos realizados por el ForTraCC	10
Figura 4. Identificación de las regiones convectivas de las nubes	14
Figura 5. Identificación del estado de los clusters entre dos tiempos consecutivos	16
Figura 6. Extracción de información de los clusters.....	17
Figura 7. Identificación de las regiones más convectivas de un cluster	18
Figura 8. Estimación de la posición de los clusters en el futuro	21
Figura 9. Percentiles empíricos de precipitación horaria	22
Figura 10. Esquema de generación y actualización de los productos del algoritmo de nowcasting	23
Figura 11. Aviso de nowcasting del SENAMHI	24
Figura 12. Esquema de selección de datos para la validación.....	25

RESUMEN

El presente trabajo de suficiencia profesional (TSP) tiene por objetivo presentar un algoritmo computacional escrito en python, que usa las informaciones del satélite GOES-16 para realizar pronósticos horarios de lluvias moderadas, fuertes y extremas, las cuales son emitidas como avisos de lluvia a muy corto plazo (nowcasting) en la página web del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Los pronósticos realizados por este algoritmo son comparados con los datos de las estaciones automáticas del SENAMHI para evaluar el desempeño de estos pronósticos.

Palabras clave: nowcasting, GOES-16, lluvia, sensoramiento remoto

ABSTRACT

The objective of this Professional Sufficiency Work (PSW) is to present a computational algorithm written in Python, which uses information from the GOES-16 satellite to make hourly forecasts of moderate, heavy and extreme rains, which are issued as very short-term rain warnings (nowcasting) on the website of the National Meteorology and Hydrology Service of Peru (SENAMHI). The forecasts made by this algorithm are compared with the data from the SENAMHI automatic stations to evaluate the performance of these forecasts.

Keywords: nowcasting, GOES-16, rain, remote sensing

I. INTRODUCCIÓN

1.1 Problemática

A nivel mundial, los pronósticos a muy corto plazo (nowcasting) son realizados con datos de radares meteorológicos, los cuales a diferencia de las imágenes de satélite brindan información del interior de las nubes permitiendo inferir los procesos termodinámicos que ocurren dentro de ellas. Este tipo de información ayuda a identificar de forma más precisa las regiones donde ocurre tiempo severo (definido en este trabajo como lluvia acumulada en 60 minutos que superan el percentil 90 de precipitación horaria de una localidad), logrando así un pronóstico más preciso que el realizado solo con datos de satélite. Desafortunadamente, en el Perú aún no se cuenta con estos instrumentos funcionando de forma operativa y si bien existen iniciativas para su implementación, este proceso puede tardar varios años en llevarse a cabo a nivel nacional.

Ante este problema, los datos de las estaciones meteorológicas automáticas pueden ser una alternativa a los datos de los radares, puesto que permiten conocer la ocurrencia e intensidad de las lluvias en tiempo real. En el Perú, el *Servicio Nacional de Meteorología e Hidrología del Perú* (SENAMHI) cuenta con una amplia red de estaciones automáticas que registran diferentes parámetros meteorológicos como la precipitación, sin embargo, este registro no es instantáneo, sino acumulado de forma horaria, el cual tardan hasta 50 minutos en llegar a la sede central del SENAMHI, lo cual impide su uso en la elaboración del nowcasting.

En ese contexto, la única alternativa de información con la que dispone el SENAMHI para realizar el nowcasting son los datos del satélite *Geostationary Operational Environmental Satellites* (GOES). Si bien, dichos datos nos proporcionan información de nubosidad en todo el continente cada 10 minutos, su principal desventaja es que esta información corresponde al tope de las nubes, con lo cual se carece de información sobre los procesos termodinámicos que ocurren en su interior. Esta ausencia de información dificulta la precisa identificación de las regiones donde ocurren y ocurrirán precipitaciones intensas en las próximas horas. Afortunadamente, la nueva generación de los satélites GOES (la serie R conformada por el GOES-16, GOES-17, GOES-18 y GOES-19) que se encuentran operativos, cuentan con

mejoras significativas respecto al detalle como a la cantidad de sus datos (Schmit et al., 2017), lo que permite inferir estos procesos termodinámicos que ocurren en el interior de las nubes (Mecikalski et al., 2006; Mecikalski et al., 2008; Mecikalski et al., 2013).

El satélite GOES-16, desarrollado por la *National Oceanic and Atmospheric Administration* (NOAA) y la *National Aeronautics and Space Administration* (NASA), a través de su sensor *Advanced Baseline Imager* (ABI) puede inferir la ocurrencia de los procesos termodinámicos del interior de las nubes mediante el monitoreo de los atributos físicos de las nubes. Estos atributos físicos son: el desarrollo vertical, la intensidad del flujo ascendente, la glaciación y el tamaño de las partículas que se observan en el tope de las nubes. Adicionalmente, la incorporación del sensor *Geostationary Lightning Mapper* (GLM) dentro de los satélites GOES de la serie R, permiten identificar la ocurrencia de descargas eléctricas las 24 horas del día. Este tipo de información es de gran importancia para identificar las regiones más convectivas de las nubes, ayudando a realizar una identificación más precisa de las áreas donde se presenten lluvias intensas.

Hasta hace algunos años, los avisos de nowcasting del SENAMHI eran elaborados a partir de los resultados generados por el algoritmo *Forecast and Tracking the Evolution of Cloud Clusters* (ForTraCC) (Vila et al., 2008), el cual realiza estimaciones de la evolución de los sistemas convectivos para las próximas horas. Si bien estos resultados eran de gran ayuda en la elaboración del nowcasting, sus estimaciones poco detalladas no permitían realizar avisos más finos, observándose en algunas ocasiones que estos avisos cubrían todo el país. El poco detalle de las estimaciones del ForTraCC se debe a que los datos que utiliza son solo imágenes infrarrojas de 4x4 Km con una resolución temporal de 30 minutos. El ForTraCC al haber sido desarrollado en el 2008 solo contaba con datos de la anterior generación de satélites GOES (GOES-12, GOES-13, GOES14 y GOES-15), la cual solo tenía 5 canales. Un contexto diferente se tiene actualmente con la nueva generación de los satélites GOES, los cuales generan una mayor cantidad de información al contar con 3 veces más bandas espectrales, 4 veces mejor resolución espacial y 5 veces mejor resolución temporal que la anterior generación. Este mayor volumen de información permite monitorear parámetros como son los atributos físicos de las nubes, las cuales pueden mejorar la estimación de lluvias intensas. Lamentablemente, el ForTracc no puede incluir estas nuevas informaciones en la generación de sus estimaciones, por lo cual los pronosticadores tuvieron que incluirlas de forma manual al momento de elaborar los avisos de nowcasting, incrementando el tiempo de emisión de estos avisos a 1 hora. Además, esta inclusión manual incorpora errores

humanos y criterios de evaluación diferentes entre los pronosticadores, disminuyendo la precisión de estos avisos. Si bien es importante que el pronosticador verifique los resultados de algoritmos como el ForTraCC, para ajustarlos si fuera necesario, este procedimiento debe ser realizado en una etapa final, como un control de calidad dentro del proceso de elaboración de estos avisos.

Es por todo lo expuesto que surge la necesidad de contar con un algoritmo que realice la detección y el pronóstico de tiempo severo, a partir de los datos del satélite GOES-16, para que sean utilizados como insumos en la generación de los avisos de nowcasting.

1.2 Objetivos

1.2.1 Objetivo General

Identificar y pronosticar la ocurrencia de tiempo severo usando informaciones del satélite GOES-16.

1.2.2 Objetivos Específicos

- Desarrollar un algoritmo computacional que realice el pronóstico de tiempo severo a partir de imágenes de satélite.
- Validar los resultados del algoritmo utilizando datos del GOES-16 para el periodo de enero a marzo del 2023.

II. REVISIÓN DE LITERATURA

2.1 GOES-16

El GOES-16 forma parte de la nueva generación de satélite geoestacionarios desarrollados por la *National Oceanic and Atmospheric Administration* (NOAA) y la *National Aeronautics and Space Administration* (NASA), la cual tiene como objetivo monitorear la atmósfera de nuestro planeta y el ambiente espacial.

El GOES-16 está localizado a 0° de latitud, 75.2°W y 35786 km de altura (WMO OSCAR, 2023). Este satélite consta de 6 instrumentos: el radiómetro Advanced Baseline Imager (ABI) el cual genera imágenes radiométricas de la atmósfera y superficie terrestre; el Geostationary Lightning Mapper (GLM) que detecta la ocurrencia de descargas eléctricas en la atmósfera; el telescopio Solar Ultra-violet Imager (SUVI) que monitorea la actividad solar; los sensores Extreme ultra-violet and X-ray Irradiance Sensors (EXIS) que mide la irradiancia el espectro ultravioleta extremo y los rayos X; los sensores Space Environment In-Situ Suite (SEISS) que monitorea los flujos de protones, electrones e iones pesados en la magnetosfera; y el Magnetometer (MAG) que monitorea el campo magnético del entorno espacial (Mission Overview GOES-R Series, s.f.).

Los 6 instrumentos del GOES-16 generan datos que presentan diferentes grados de complejidad según el nivel de procesamiento al que fueron sometidos. Un mayor detalle de estos niveles de procesamiento es presentado en la Tabla 1.

Tabla 1: Niveles de procesamiento de los datos del GOES-16

Nivel	Descripción
0	Datos originados por el instrumento sin ningún tipo de procesamiento
1b	Datos con correcciones radiométricas y geométricas que se encuentran en unidades físicas
2+	Datos con información derivada del nivel 1

FUENTE: Elaboración a partir de Ground System GOES-R Series. (s.f.)

Debido a la importancia que tiene el ABI y GLM en el monitoreo atmosférico, en las siguientes subsecciones se describe con mayor detalle cada uno de estos instrumentos.

2.1.1 ABI

El generador de imágenes ABI es un radiómetro pasivo que mide la radiación emitida y reflejada por la atmósfera y la superficie terrestre, en 16 bandas espectrales (ver Tabla 2). En comparación con los generadores de imágenes de la anterior generación de satélites GOES (GOES 12, 13, 14 y 15), el ABI genera imágenes con 4 veces mayor resolución espacial, 5 veces más resolución temporal y 3 veces más resolución espectral.

Tabla 2: Descripción de las bandas del ABI

Banda	Longitud de onda central (μm)	Resolución espacial en el subpunto del satélite (km)	Nombre descriptivo
1	0.47	1	Azul
2	0.64	0.5	Rojo
3	0.864	1	Vegetación
4	1.373	2	Cirrus
5	1.61	1	Nieve/hielo
6	2.24	2	Tamaño de las partículas
7	3.90	2	Ventana de onda corta
8	6.19	2	Vapor de agua de niveles altos
9	6.93	2	Vapor de agua de niveles medios
10	7.34	2	Vapor de agua de niveles bajos-medios
11	8.44	2	Fase del tope de la nube
12	9.61	2	Ozono
13	10.33	2	Ventana de onda larga limpia
14	11.21	2	Ventana de onda larga
15	12.29	2	Ventana de onda larga sucia
16	13.28	2	Dióxido de carbono

FUENTE: Elaboración a partir de Schmit et al. (2005) y Schmit et al. (2017).

El ABI tiene múltiples modos de escaneo. El *modo 3*, también denominado “*flex mode*”, produce imágenes del hemisferio oeste completo cada 15 minutos, una imagen de 3000 km por 5000 km de los Estados Unidos denominada *Continental United States* (CONUS) cada 5

minutos, 2 imágenes de mesoescala de 1000 km por 1000 km cada 60 segundos o cada 30 segundos en un subdominio. El *modo 4*, también denominado “*full disk mode*”, produce imágenes del hemisferio oeste completo cada 5 minutos. El *modo 6*, conocido también como “*10-minute flex mode*”, que es el modo de escaneo por defecto del GOES-16. Este modo genera una imagen del hemisferio oeste completo cada 10 minutos, un CONUS cada 5 minutos y 2 imágenes de mesoescala cada 60 segundos o cada 30 segundos en un subdominio (ABI GOES-R Series, s.f.).

2.1.2 GLM

El GLM es un instrumento que mide la radiación proveniente de la atmósfera y de la superficie terrestre con el objetivo de identificar la ocurrencia de descargas eléctricas diurnas y nocturnas. Es capaz de detectar la ocurrencia de descargas eléctricas del tipo nube-nube, intra-nube y nube-suelo, sin embargo no puede diferenciarlas entre ellas (Goodman et al., 2013; Rudlosky et al., 2019). Su dominio de medición comprende entre 54°S y 54°N (Rudlosky et al., 2019). Presenta una eficiencia de detección mayor al 70% y una razón de falsa alarma menor al 5% (Rudlosky & Virts, 2021).

El GLM identifica la ocurrencia de descargas eléctricas a través de la medición de energía, en el espectro de 777.4 nm, proveniente de la atmósfera de nuestro planeta. Este proceso es realizado cada 2 milisegundos dentro de una región de observación conformada por 1372x1300 píxeles cuyo tamaño va desde los 8 Km (debajo del satélite) hasta los 14 km (en los bordes de la región de observación) (ver Figura 1).

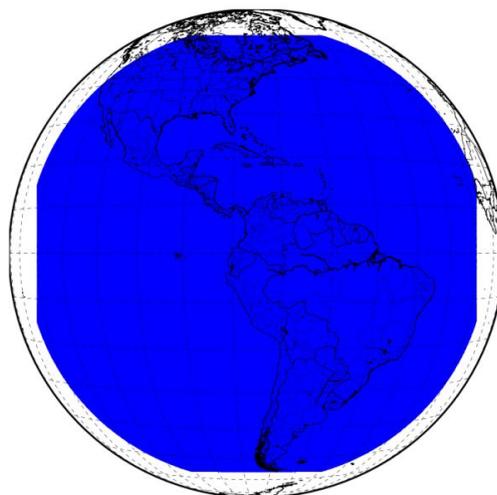


Figura 1. Región de observación del GLM (región en azul)

La energía que el GLM mide en cada uno de estos píxeles es evaluada siguiendo una serie de criterios que permite determinar si la energía medida proviene de una descarga eléctrica,

de ser este el caso, el píxel que registró esta energía será catalogado como un “evento”. El GLM tiene 3 productos principales: los “eventos”, los “grupos” y los “flashes”. Los “eventos” son el producto más básico del GLM y está formado por todos los píxeles cuya energía está asociada con la ocurrencia de descargas eléctricas. Los “grupos” son el conjunto de “eventos” que se encuentran localizados de forma adyacentes, mientras que los “flashes” están formados por aquellos “grupos” que tienen una separación espacial menor a 16.5 Km y una separación temporal no mayor a 330 ms entre ellos (ver Figura 2). Cada uno de los productos del GLM brinda información relacionada con las descargas eléctricas como es el área, la energía, la duración, las coordenadas, etc. Todas estas informaciones son almacenadas en archivos netcdf y emitidas cada 20 segundos.

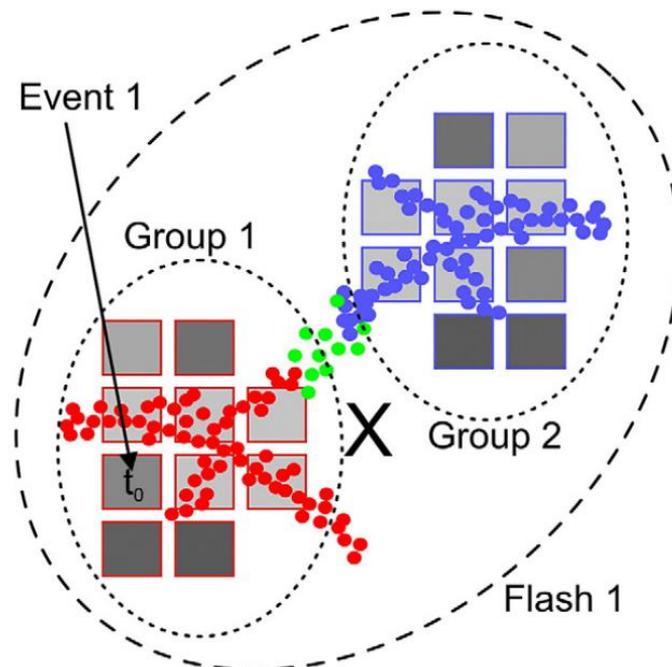


Figura 2. Representación gráfica de los productos del GLM
 Comparación entre la ubicación de las descargas eléctricas observada por una red de detección en superficie (puntos rojos, verdes y azules) y la ubicación de los productos del GLM: “eventos” (cuadrículas grises), “grupos” (conjunto de cuadrículas grises adyacentes) y “flash” (conjunto de grupos) cuya coordenada central es representado por una “X”.

FUENTE: tomado de Goodman et al. (2013)

2.2 Atributos Físicos de las Nubes

De forma general se puede indicar que la ocurrencia de tiempo severo está estrechamente relacionada con la intensidad del flujo ascendente dentro de la nube y la disponibilidad de vapor de agua en la atmósfera.

Las corrientes ascendentes, próximas a superficie, generan el ascenso del vapor de agua presente en los niveles bajos de la atmósfera, el cual se condensa y forma gotas de agua que dan origen a las nubes en una etapa denominada “iniciación convectiva”. Si las corrientes ascendentes siguen presentes en el interior de la nube, las gotas de agua continuarán ascendiendo, produciendo un desarrollo vertical de la nube al mismo tiempo que la temperatura de su tope se vuelve cada vez más fría. De continuar ascendiendo hasta superar la isoterma de 0°C, las gotas de agua irán cambiando su estado físico de líquido a sólido, formando cristales de hielo. Este cambio ocurre inicialmente en las partes altas de la nube, en un proceso denominado “glaciación en el tope de la nube”. Si el flujo ascendente sigue presente, las gotas de agua y los cristales de hielo colisionan entre ellos formando hidrometeoros de un mayor tamaño. De ser el flujo ascendente lo suficientemente intenso para elevarlos, se podrá observar un aumento del tamaño de estos hidrometeoros en el tope de la nube.

La colisión entre los hidrometeoros sólidos (cristales de hielo, granos de hielo y granizo) genera también el intercambio de cargas en el interior de la nube, ocasionando la formación de campos electromagnéticos. Cuando estos campos electromagnéticos superan la capacidad aislante del aire (rigidez dieléctrica) ocurren las primeras descargas eléctricas. Conforme estos campos electromagnéticos continúen intensificando, la cantidad de descargas eléctricas irá aumentando, observándose una relación de causa y efecto donde una mayor intensidad del flujo ascendente dentro de la nube, se corresponde con un mayor número de descargas eléctricas.

Por otro lado, cuando el flujo ascendente dentro de la nube disminuye o se desplaza a otras regiones, los hidrometeoros que estuvieron en suspensión caen, dando inicio a precipitaciones tanto sólidas como líquidas. Teniendo presente que un flujo ascendente más intenso puede mantener en suspensión un mayor número de hidrometeoros, podríamos esperar precipitaciones más intensas cuando se observan flujos ascendentes intensos.

A partir de todas estas relaciones se puede establecer que los atributos físicos de las nubes (el flujo ascendente, el desarrollo vertical de las nubes, el tamaño de los hidrometeoros y la glaciación en el tope de la nube) pueden ser usados como indicadores de la ocurrencia de precipitaciones intensas que pueden estar acompañadas de descargas eléctricas. En ese sentido, la información del GOES-16 puede ser usada para monitorear el comportamiento de estos atributos físicos. Roberts & Rutledge (2003) mencionan que la banda de 10.7 μm

permite conocer el enfriamiento de los topos de las nubes cuando estas son menores que 0°C, lo cual permite anticiparnos entre 15 y 30 minutos a la ocurrencia de lluvias. Mecikalski & Bedka (2006) indican que una disminución entre -4 K y -8 K de la temperatura de brillo (10.7 μm) en 15 minutos, se asocian con flujos ascendentes débiles, mientras que valores menores que -8 K se asocian con flujos ascendentes intensos. Ackerman et al. (1990) indican que la diferencia entre 8.5 μm y 11.2 μm permite monitorear el tamaño de los cristales de hielo en el tope de las nubes. Por su parte, Strabala et al. (1994) indican que la diferencia tris-espectral [(8.5 μm - 11.2 μm) - (11.2 μm - 12.3 μm)] permite identificar la glaciación en el tope de la nube. Las descargas eléctricas que presentan relación con estos atributos físicos, también pueden ser usados como indicadores de la ocurrencia de tiempo severo. Goodman et al. (1988) encontró que minutos previos a la ocurrencia de lluvias intensas, se observan incrementos repentinos del número de descargas, lo cual denominó como “lightning jump”. Ribeiro et al. (2019) indican que los atributos físicos de las nubes junto con la identificación de estos “lightning jump” pueden ser usados como indicador de la ocurrencia de lluvias intensas y/o granizadas en los próximos minutos.

2.3 ForTraCC

El *Forecast and Tracking the Evolution of Cloud Clusters* (ForTraCC) es un algoritmo desarrollado por Vila et al. (2008), escrito en el lenguaje de programación fortran, que realiza el seguimiento y el pronóstico de la evolución de los sistemas convectivos. Fue desarrollado para trabajar con las imágenes infrarrojas de la banda 10.8 μm de la anterior generación del satélite GOES (GOES-12, 13, 14 y 15), las cuales tenían una resolución espacial de 4 Km y una resolución temporal de 30 minutos.

El ForTraCC realiza el seguimiento de todos aquellos grupos de píxeles (“clusters”) con temperaturas de brillo menores a 235 K. El seguimiento de estos clusters a través del tiempo permite obtener informaciones morfológicas (tamaño, área, centro de masa, etc) y radiativas (temperatura de brillo media, mínima y el promedio de los 9 píxeles más fríos) de las nubes, las cuales son usadas para estimar su evolución en los próximos minutos.

El ForTraCC basa sus estimaciones en la ecuación de expansión de área normalizada $\Delta E = 1/A(\delta A/\delta t)$ (Machado et al. 1998; Machado and Laurent 2004), la cual al ser ajustada como una ecuación lineal $\Delta E = at + b$ (donde “a” es la pendiente, “b” la intercepción y “t” el tiempo), permite obtener un modelo que estima la tasa de crecimiento y la variación de la

temperatura de los sistemas convectivos. Este modelo junto con la extrapolación del movimiento de los clusters logran hacer estimaciones de hasta 120 minutos (ver Figura 3).

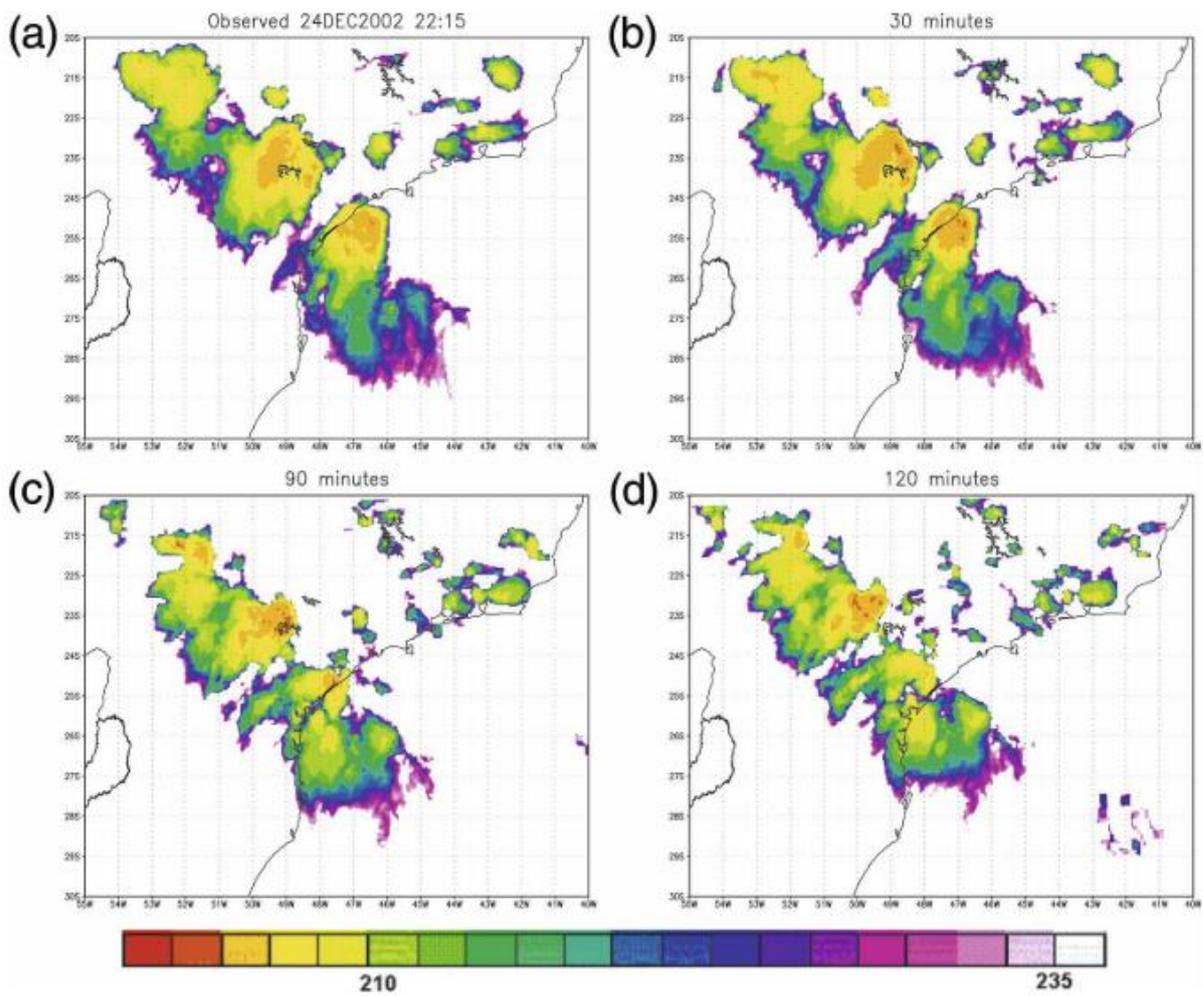


Figura 3. Pronósticos realizados por el ForTraCC
Cobertura de nubes frías a las 2245 UTC del 24 de diciembre de 2002 dentro de una región de la cuenca De La Plata en el sureste de Brasil. Imagen observada (a), imagen pronosticada a 30 minutos (b), imagen pronosticada a 90 minutos (c) e imagen pronosticada a 120 minutos.
FUENTE: tomado de Vila et al. (2008).

III. DESARROLLO DEL TRABAJO

El siguiente proyecto de monografía de tipo no experimental, consiste en identificar y pronosticar, de forma automática, la ocurrencia de tiempo severo (definido en este trabajo como lluvia acumulada en 60 minutos que superan el percentil 90 de precipitación horaria de una localidad) dentro del territorio peruano, a partir del uso de datos del satélite GOES-16. Para ello se desarrolló un código computacional, escrito en el lenguaje de programación python, el cual evalúa el comportamiento de los atributos físicos de las nubes y la ocurrencia de descargas eléctricas para realizar sus estimaciones.

3.1 Área de Estudio y Datos

El área de estudio de este trabajo se encuentra entre 1.0° y -19.0° de latitud y entre -82° y -68.0° de longitud, abarcando todo el territorio peruano.

Los datos utilizados corresponden a los sensores ABI y GLM del GOES-16. En el caso del ABI, la información utilizada corresponde a las imágenes del canal 13, las cuales fueron procesadas para llevarlas de su proyección satelital original a una proyección equirectangular de 2 km. A partir de estos datos se estimó la intensidad del flujo ascendente y el desarrollo vertical de las nubes, las cuales fueron utilizadas como indicadores de severidad. En el caso del GLM se utilizó el producto “Flash”, el cual fue acumulado en grillas de 2×2 km (la misma que el canal 13), dentro de un intervalo de tiempo de 10 minutos (entre 5 minutos antes y 5 minutos después del horario de la imagen del canal 13) para calcular la densidad de flash en 10 minutos (DF10min).

Los datos del ABI y del GLM que se usaron en este estudio corresponden a los meses de enero, febrero y marzo de 2023, siendo los primeros días de enero destinados a la elaboración del algoritmo de nowcasting y los días restantes destinados a la validación de los resultados. De los días destinados para la validación se seleccionaron las fechas con el mayor número de estaciones que superaron su percentil 90 de precipitación diaria. La razón de usar este criterio se debe a la falta de una estadística de percentiles horarios que sirva como umbral para determinar si la precipitación horaria se puede considerar como intensa o no. Basados

en la idea de que las estaciones que superan su percentil 90 de precipitación diaria, muy posiblemente presentaron una o más horas con precipitaciones intensas, se decide adoptar este criterio para identificar las fechas para la validación. La información de las estaciones que superan su percentil 90 de precipitación diaria fue obtenida de los reportes del monitoreo meteorológico del SENAMHI (<https://www.senamhi.gob.pe/?&p=monitoreo-meteorologico>). En la Tabla 3 se muestran las fechas utilizadas en la validación. Estas fechas comprenden entre las 7 horas de un día hasta las 7 horas del día siguiente. La razón de utilizar este rango de horas es porque la precipitación diaria, mostrada en los reportes del monitoreo meteorológico, ha sido registrada en ese intervalo de tiempo. Otra razón para considerar este intervalo de tiempo es que permite incluir horarios que presentaron diferentes intensidades de precipitación, con lo cual se evalúa la capacidad del algoritmo tanto para pronosticar precipitaciones intensas como para no pronosticarlas. De esta forma, al incluir este rango de horas se aseguró que en la evaluación no hubieran sesgos debido a la ausencia o escasez de casos con un determinado valor de precipitación.

Tabla 3: Fechas y horarios de los datos de satélite usadas en la validación

Fecha y hora de inicio y fin (hora Perú)	Fecha y hora de inicio y fin (hora Perú)
2023-01-19 07:00 - 2023-01-20 07:00	2023-03-05 07:00 - 2023-03-06 07:00
2023-01-21 07:00 - 2023-01-22 07:00	2023-03-06 07:00 - 2023-03-07 07:00
2023-01-29 07:00 - 2023-01-30 07:00	2023-03-07 07:00 - 2023-03-08 07:00
2023-01-30 07:00 - 2023-01-31 07:00	2023-03-08 07:00 - 2023-03-09 07:00
2023-01-31 07:00 - 2023-02-01 07:00	2023-03-09 07:00 - 2023-03-10 07:00
2023-02-03 07:00 - 2023-02-04 07:00	2023-03-10 07:00 - 2023-03-11 07:00
2023-02-04 07:00 - 2023-02-05 07:00	2023-03-11 07:00 - 2023-03-12 07:00
2023-02-05 07:00 - 2023-02-06 07:00	2023-03-12 07:00 - 2023-03-13 07:00
2023-02-12 07:00 - 2023-02-13 07:00	2023-03-13 07:00 - 2023-03-14 07:00
2023-02-13 07:00 - 2023-02-14 07:00	2023-03-14 07:00 - 2023-03-15 07:00
2023-02-14 07:00 - 2023-02-15 07:00	2023-03-15 07:00 - 2023-03-16 07:00
2023-02-17 07:00 - 2023-02-18 07:00	2023-03-17 07:00 - 2023-03-18 07:00
2023-02-18 07:00 - 2023-02-19 07:00	2023-03-23 07:00 - 2023-03-24 07:00
2023-02-20 07:00 - 2023-02-21 07:00	2023-03-24 07:00 - 2023-03-25 07:00
2023-02-21 07:00 - 2023-02-22 07:00	2023-03-29 07:00 - 2023-03-30 07:00
2023-02-22 07:00 - 2023-02-23 07:00	2023-03-30 07:00 - 2023-03-31 07:00
2023-02-23 07:00 - 2023-02-24 07:00	2023-03-31 07:00 - 2023-04-01 07:00
2023-02-27 07:00 - 2023-02-28 07:00	

Fechas y horas de las imágenes utilizadas en la validación de los resultados del algoritmo de nowcasting.

3.2 Metodología

El desarrollo de este trabajo se basa principalmente en la creación de un algoritmo computacional en python que identifique las nubes convectivas, extraiga información de ellas y realice estimaciones de su evolución, para pronosticar la ocurrencia de precipitaciones intensas en las siguientes horas.

3.2.1 Identificación de Nubes Convectivas

Para identificar las nubes con características convectivas se eliminaron, de las imágenes del canal 13, todos los píxeles con temperatura de brillo mayores a 235 K. El uso de este umbral se basa en los trabajos de Laurent et al. (2002), Machado y Laurent (2004) y Carvalho y Jones (2001) quienes indican que temperaturas de brillo menores o iguales a 233 K se asocian con nubes convectivas observadas en sudamérica. En nuestro caso se adaptó este umbral a 235 K para identificar nubes de menor desarrollo vertical. Los grupos de píxeles que cumplen con esta condición son denominados como “clusters” e indican regiones con nubes convectivas. Estos clusters son filtrados de acuerdo a su tamaño, siendo preservados sólo aquellos que sean iguales o mayores que 10 píxeles (40 Km²). Este procedimiento es realizado para evitar trabajar con clusters pequeños que desaparecen de una imagen a otra y que dificultan el seguimiento de los clusters a través del tiempo. Los clusters que pasan este filtro son enumerados y seguidamente se les aplica otros umbrales de temperatura de brillo para identificar las regiones convectivas que alcanzan niveles altos ($TB \leq 218$ K) y las regiones convectivas mucho más profundas ($TB \leq 203$ K) (Vila y Machado (2004)). En la Figura 4 se muestra un ejemplo de la identificación de las regiones convectivas de una nube, aplicando estos umbrales de temperatura de brillo.

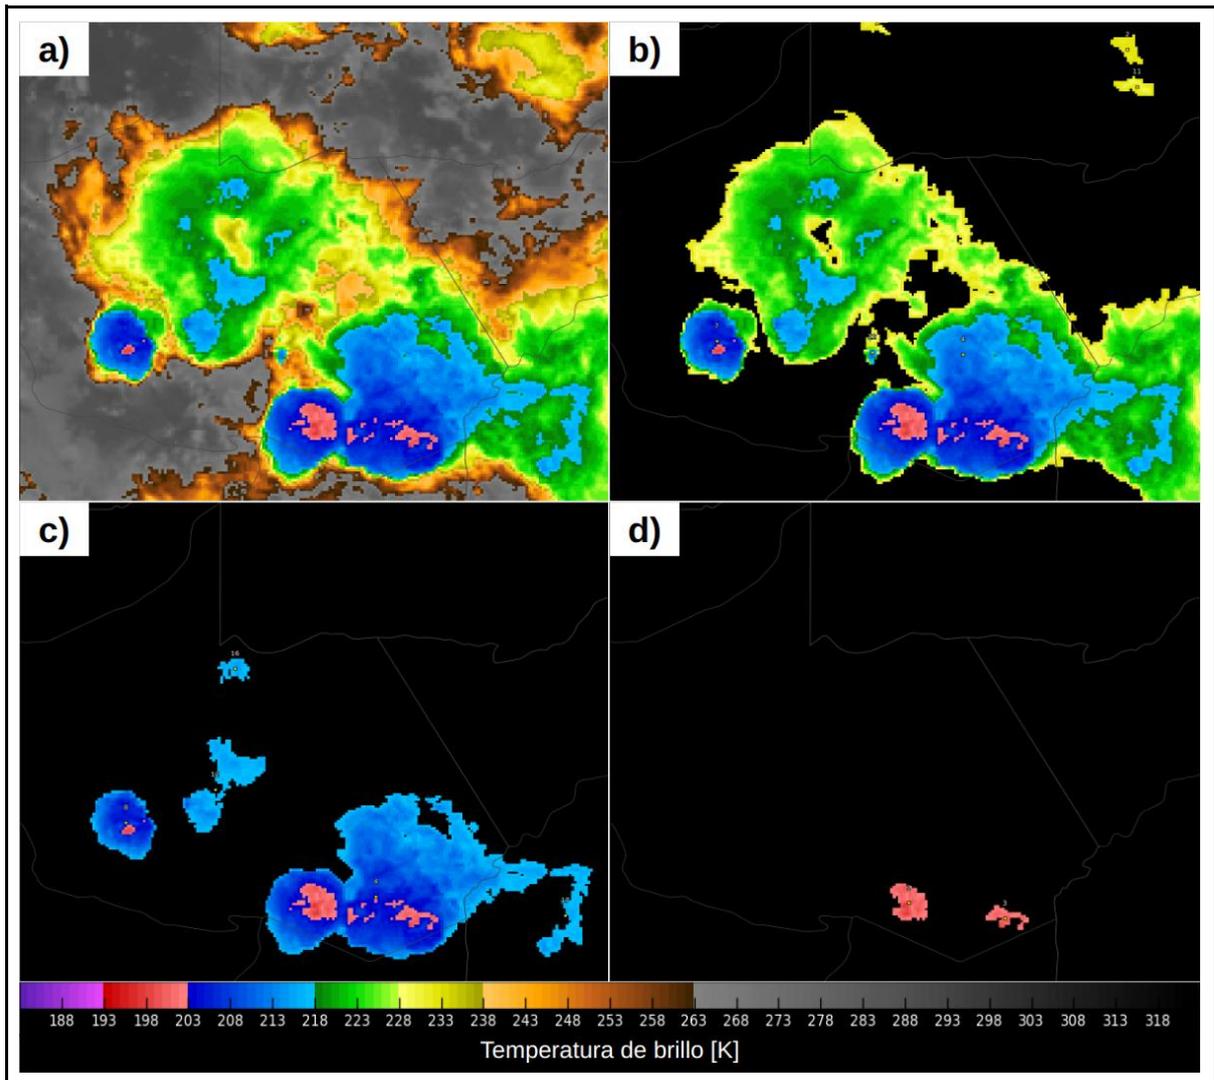


Figura 4. Identificación de las regiones convectivas de las nubes
 Imagen de temperatura de brillo del canal 13 (a) acompañada de la misma imagen mostrando la delimitación de un cluster ($TB \leq 235$ K)(b), la delimitación de nubes convectivas que alcanzan niveles altos ($TB \leq 218$ K)(c) y la delimitación de nubes convectivas mucho más profundas ($TB \leq 203$ K) (d).

3.2.2 Identificación de Clusters a Través del Tiempo

La identificación de los clusters a través del tiempo se realiza mediante la sobreposición de los clusters del tiempo actual con los clusters del tiempo anterior, si existe sobreposición entre ellos, el cluster del tiempo anterior le asigna su numeración al cluster del tiempo actual. Si bien esta es la idea básica para la identificación de los clusters a través del tiempo, este método sólo es válido para los cluster que mantienen su continuidad (“Continuous”), sin embargo existen otros casos en donde los clusters se unen a otros clusters (“Merge”), cluster que se dividen (“Split”), cluster que aparecen (“New”) y clusters que se disipan, volviendo muy complejo este proceso. En la Tabla 4 se describe el criterio utilizado para enumerar e identificar el estado de los clusters (“New”, “Continuous”, “Split”, “Merge”, “Special-

Split”, “Special-Merge”) en cada una de estas situaciones, mientras que en la Figura 5 se muestra una representación gráfica de cada una de ellas.

Tabla 4: Criterios para la numeración y denominación de los clusters

Situación	Estado
Cuando un cluster del tiempo actual no intercepta a ningún cluster del tiempo anterior, se etiqueta a este cluster como “ New ” y su numeración continua a la numeración alcanzada por los clusters en el tiempo anterior.	New
Cuando un cluster del tiempo actual intercepta solo a un cluster del tiempo anterior, se etiqueta a este cluster como “ Continuous ” y su numeración es la misma que el cluster del tiempo anterior.	Continuous
Cuando un cluster del tiempo actual intercepta a más de un cluster del tiempo anterior, se etiqueta a este cluster como “ Merge ” y su numeración es la misma que el cluster del tiempo anterior que presenta mayor área de superposición con el cluster del tiempo actual.	Merge
Cuando un cluster del tiempo actual intercepta a un cluster del tiempo anterior y este último también intercepta a otros clusters en el tiempo actual, se etiqueta a todos los clusters del tiempo actual como “ Split ”. El cluster del tiempo actual que presente mayor área de superposición con el cluster del tiempo anterior es el que hereda su numeración, mientras que la numeración de los otros clusters continúan a la numeración alcanzada por los clusters del tiempo anterior.	Split
Cuando un cluster del tiempo actual intercepta a un cluster del tiempo anterior y este último también se une a otros clusters del tiempo anterior para formar clusters en el tiempo actual, se etiqueta a este cluster como “ Special-Split ”. De todo el conjunto de clusters, el que presente mayor superposición con el cluster del tiempo anterior heredará su numeración, la numeración de los otros clusters continúan a la numeración alcanzada por los clusters en el tiempo anterior.	Special-Split
Cuando un cluster del tiempo actual intercepta a más de un cluster del tiempo anterior y uno de estos clusters del tiempo anterior intercepta a uno o más clusters en el tiempo actual, se etiqueta a los clusters del tiempo actual como “ Special-Merge ”. El cluster que presente mayor superposición con el cluster del tiempo anterior heredará su numeración, los otros clusters continuarán con la numeración alcanzada por los clusters en el tiempo anterior.	Special-Merge

Metodología utilizada para determinar el estado y la numeración de un cluster a través del tiempo.

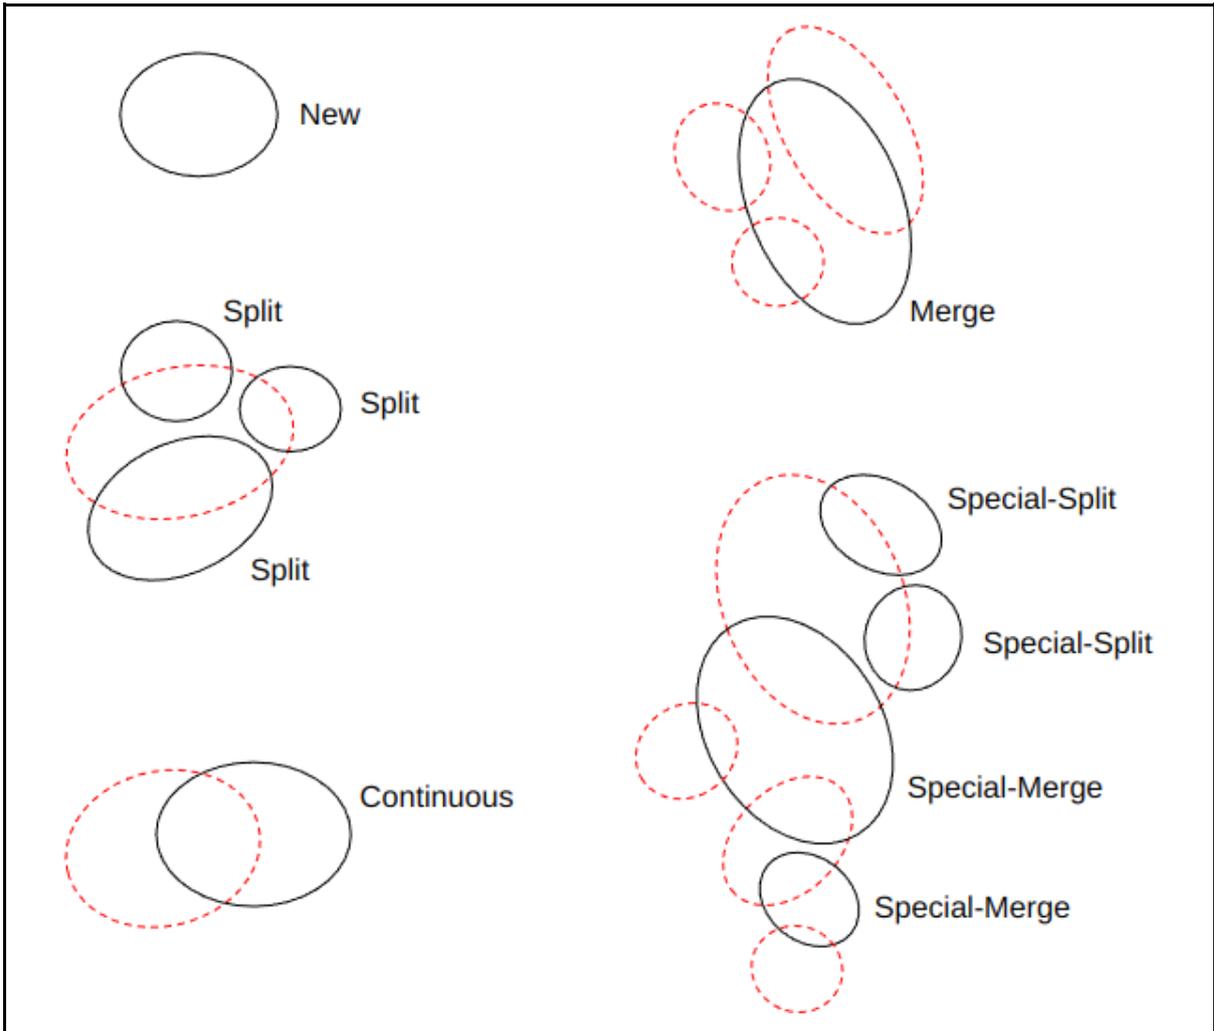


Figura 5. Identificación del estado de los clusters entre dos tiempos consecutivos
Identificación del estado de los clusters del tiempo actual (negro), basados en su sobreposición con los clusters del tiempo anterior (rojo).

3.2.2 Extracción de Información de los Clusters

Luego de identificar los clusters a través del tiempo se extrajeron informaciones radiativas y morfológicas de cada uno de ellos. Las informaciones radiativas extraídas fueron la temperatura de brillo mínima (TBmin) y su variación en 10 minutos ($\Delta TB_{min10min}$), mientras que las informaciones morfológicas fueron el tamaño de los clusters y su centro de masa ponderado (CM). El CM es definido en la Ecuación 1.

$$CM = (LonPon, LatPon) \quad \dots \quad (Ecuación 1)$$

donde $LonPon$ y $LatPon$ son la longitud y la latitud ponderada del clúster, las cuales se definen como la Ecuación 2 y la Ecuación 3, respectivamente.

$$LonPon = \sum_{i=1}^n \frac{Lon_i \cdot TB_i}{n} \quad \dots \quad (\text{Ecuación 2})$$

$$LatPon = \sum_{i=1}^n \frac{Lat_i \cdot TB_i}{n} \quad \dots \quad (\text{Ecuación 3})$$

donde Lon_i , Lat_i y TB_i representan la longitud, la latitud y la temperatura de brillo de cada píxel que conforma el cluster.

Adicionalmente a las informaciones radiativas y morfológicas, también se extrajo la máxima densidad de flash acumulada en 10 minutos (MaxDF10min) registrada dentro del clúster. En la Figura 6 se muestra una representación de la extracción de la información radiativa y la actividad eléctrica de un cluster.

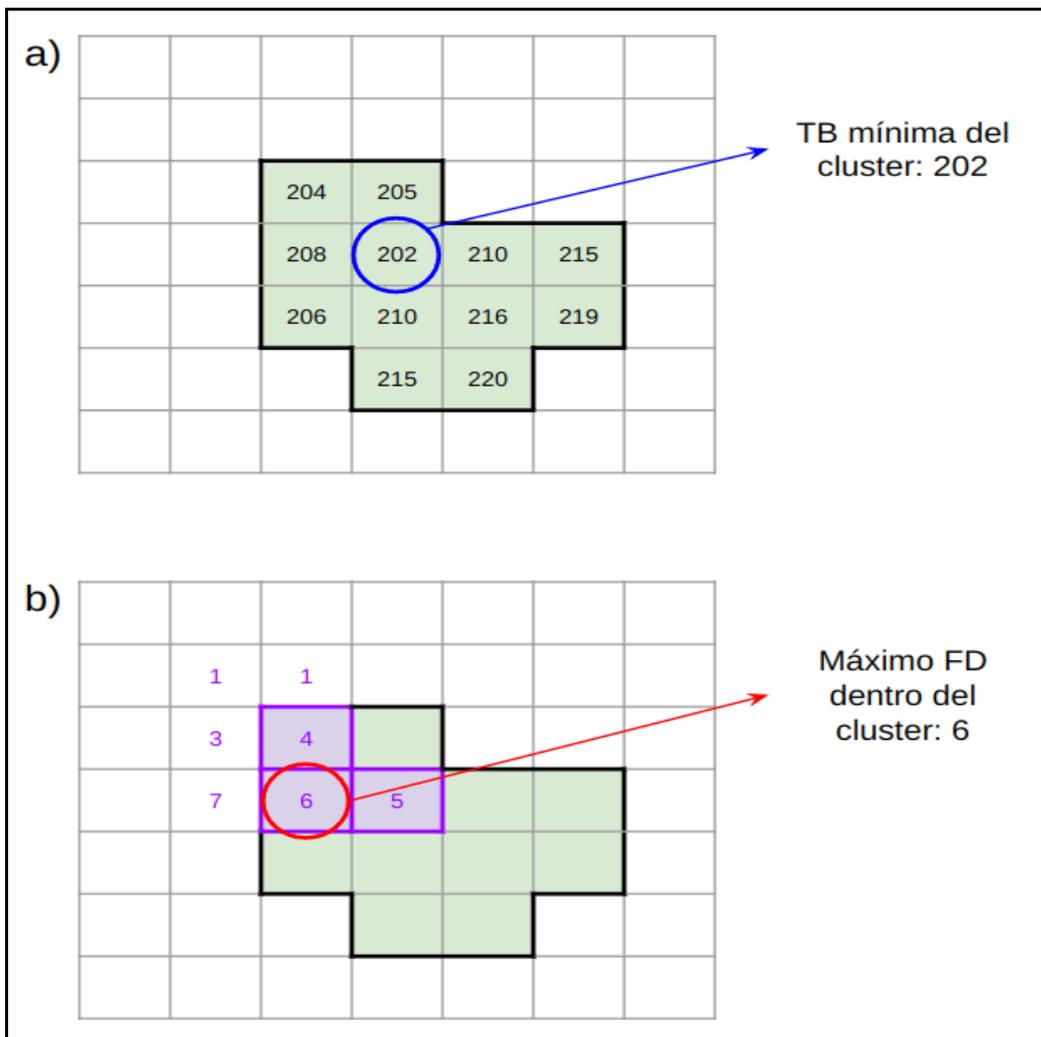


Figura 6. Extracción de información de los clusters

Sobreposición de un cluster (delimitados por la línea negra) con la imagen del canal 13 del GOES (a) y con densidad de flash acumulada en 10 minutos DF10min(b) para obtener la TB mínima y la máxima densidad de flash dentro del cluster.

La extracción de la información radiativa, morfológica y eléctrica también fue realizada dentro de las regiones convectivas que presentan los clusters (regiones con $TB \leq 218$ K y regiones con $TB \leq 203$ K).

3.2.3 Evaluación de Severidad

La identificación de la severidad estuvo comprendida por 2 etapas. La primera etapa consistió en asignar niveles de severidad por parámetro ($\Delta TB_{min10min}$ y $MaxDF_{10min}$) a los clusters; mientras que la segunda etapa consistió en unificar estos niveles de severidad en un nivel de severidad total. Para la asignación de niveles de severidad por parámetro primero tuvo que identificarse el número de umbrales de TB que presenta el cluster para luego descartar la región menos convectiva. Si un cluster presenta 1 o 2 umbrales de TB, estas regiones son conservadas sin modificaciones (ver Figura 7a y 7b), pero si el cluster presenta 3 umbrales de TB, se elimina la región con el umbral menos convectivos (ver Figura 7c). Este procedimiento es realizado con el objetivo de reducir el tamaño de las áreas alertadas y preservar la región más convectiva, la cual se asocia con tiempo severo.

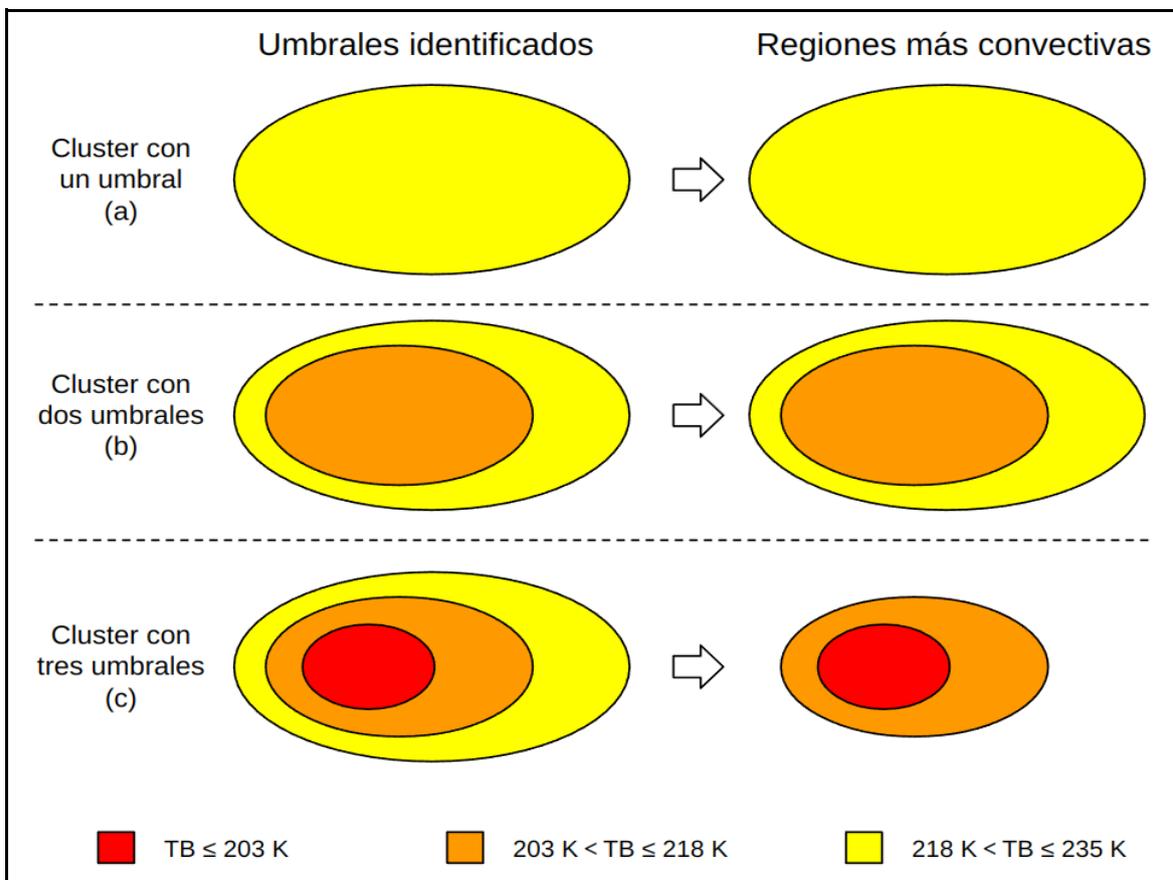


Figura 7. Identificación de las regiones más convectivas de un cluster

Identificación de las regiones más convectivas de un cluster cuando presenta un umbral de TB (a), dos umbrales de TB (b) y tres umbrales TB (c).

En las regiones más convectivas de los clusters se evaluó la $\Delta TB_{min10min}$ y se le asignó niveles de severidad según sus valores, tal cual se observa en la Tabla 5. De forma similar, a estas mismas regiones convectivas se le asignó niveles de severidad basado en sus valores de $MaxDF_{10min}$, como se indica en la Tabla 6.

Tabla 5: Niveles de severidad basados en la variación de la temperatura de brillo

Nivel de severidad	$\Delta TB_{min10min}$
1	$\Delta TB_{min10min} > -4 \text{ K}$
2	$-8 \text{ K} < \Delta TB_{min10min} \leq -4 \text{ K}$
3	$\Delta TB_{min10min} \leq -8 \text{ K}$

Niveles de severidad que se le asignan a un clúster según la variación en 10 minutos de la temperatura de brillo mínima registrada en el clúster. Fuente: elaboración propia.

Tabla 6: Niveles de severidad basados en la máxima densidad de flash en 10 minutos

Nivel de severidad	$MaxDF_{10min}$
1	$1 \leq MaxDF_{10min} < 5$
2	$5 \leq MaxDF_{10min} < 20$
3	$MaxDF_{10min} \geq 20$

Niveles de severidad que se le asignan a un cluster según la máxima densidad de flash registrada en el cluster.

En el caso de la $\Delta TB_{min10min}$, los umbrales que definen los niveles de severidad se basan en los umbrales propuestos por Mecikalski y Bedka (2006). Según estos autores, los valores entre -4K y -8K de la ΔTB en 15 minutos se asocia con flujos ascendentes débiles, mientras que valores menores que -8 K se asocian con flujos ascendentes intensos. Estos valores fueron adaptados a intervalos de 10 minutos para que puedan ser aplicados a las imágenes del GOES-16. En el caso de la $MaxDF_{10min}$, los umbrales utilizados fueron definidos de forma empírica, tomando como referencia casos de gran actividad eléctrica.

Luego de asignar niveles de severidad por parámetro se sumó el valor de ambos para obtener un nivel de severidad total. El mínimo valor de esta operación es 1 y el máximo valor es 3.

Este procedimiento fue aplicado solo al umbral más convectivo del cluster, en los casos donde el cluster presentó 2 umbrales convectivos se le aplicó este procedimiento a la región más convectiva y a la región menos convectiva se le asignó un nivel de severidad igual a 1. En la Tabla 7 se presentan los niveles de severidad total junto a su nivel de alerta y su interpretación.

Tabla 7: Tabla de severidad total y su interpretación

Nivel de severidad total	Nivel de alerta	Interpretación
1	Amarillo	Probable lluvia moderada
2	Naranja	Probable lluvia fuerte
3	Rojo	Probable lluvia extrema

Niveles de severidad total de los clusters, acompañado de su nivel de alerta y su interpretación.

3.2.4 Estimación de la Posición de los Clusters

A partir de las 2 últimas imágenes procesadas, el algoritmo de nowcasting calcula el vector desplazamiento (V), el cual permite estimar la posición de los clusters en los próximos minutos. Este vector es obtenido a partir de los vectores V_{Lon} y V_{Lat} (ver Ecuación 4), los cuales representan el desplazamiento, del centro de masa ponderado de los clusters, en la longitud y la latitud, respectivamente.

$$V = V_{Lon} + V_{Lat} \quad \dots \quad (Ecuación 4)$$

La estimación de la posición se realiza trasladando los píxeles de cada cluster según el valor de su vector de desplazamiento. Este procedimiento permite estimar la posición de los cluster para los siguientes 10 minutos. Si este procedimiento es realizado 2 veces, usando el mismo valor del vector de desplazamiento, se logra estimar la posición de los clusters para los próximos 20 minutos. Si este procedimiento es realizado 3 veces se estima la posición de clusters para los próximos 30 minutos (ver Figura 8). En nuestro caso, para estimar la posición de los clusters para las próximas 2 horas se tuvo que realizar este procedimiento 11 veces. Estas estimaciones son realizadas en las regiones convectivas de los clusters, es decir, en las regiones que tienen asignado un nivel de severidad total.

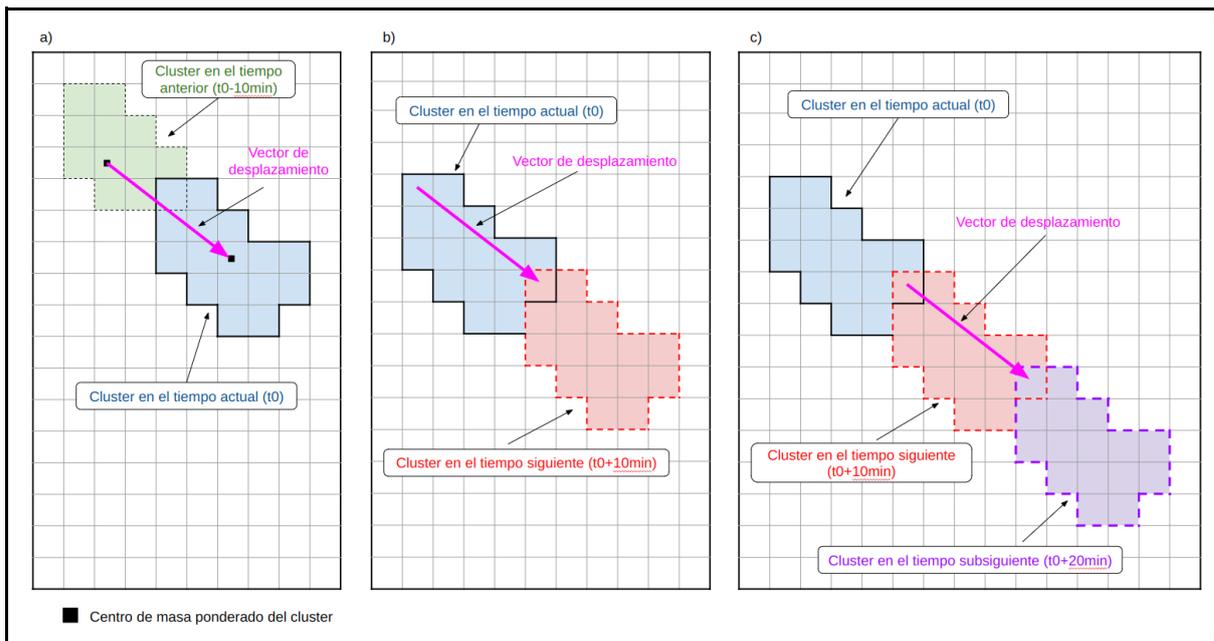


Figura 8. Estimación de la posición de los clusters en el futuro

3.2.5 Conversión de Severidad a Precipitación

Los niveles de severidad total indican de forma cualitativa la intensidad de la precipitación estimada, sin embargo para la gestión de riesgo de desastres es necesario contar con una estimación cuantitativa de esta variable. Por este motivo se le asignó a cada nivel de severidad total un rango de precipitación horaria que varía según la ubicación del centro de masa ponderado del clúster. De este modo, un cluster con un nivel de severidad total de 1 (nivel de alerta “amarillo”) presenta un diferente umbral de precipitación en la costa que en la sierra o en la selva, realizando así, un ajuste regional a los pronósticos.

Ante la ausencia de percentiles de precipitación horaria (percentil 90, 95 y 99) que permita asignar a los niveles de severidad total un intervalo de precipitación horaria, se tuvieron que crear estos percentiles basados en el conocimiento empírico de los pronosticadores de la sede central y de las direcciones zonales del SENAMHI. De esta forma, los percentiles empíricos 90 y 95 definieron los rangos de precipitación horaria del nivel de severidad total 1, los percentiles empíricos 95 y 99 definieron los rangos de precipitación horaria del nivel de severidad total 2 y el percentil empírico 99 definió la precipitación horaria mínima del nivel de severidad total 3. En la Figura 9 se presentan los valores de los percentiles empíricos 90, 95 y 99 de precipitación horaria.

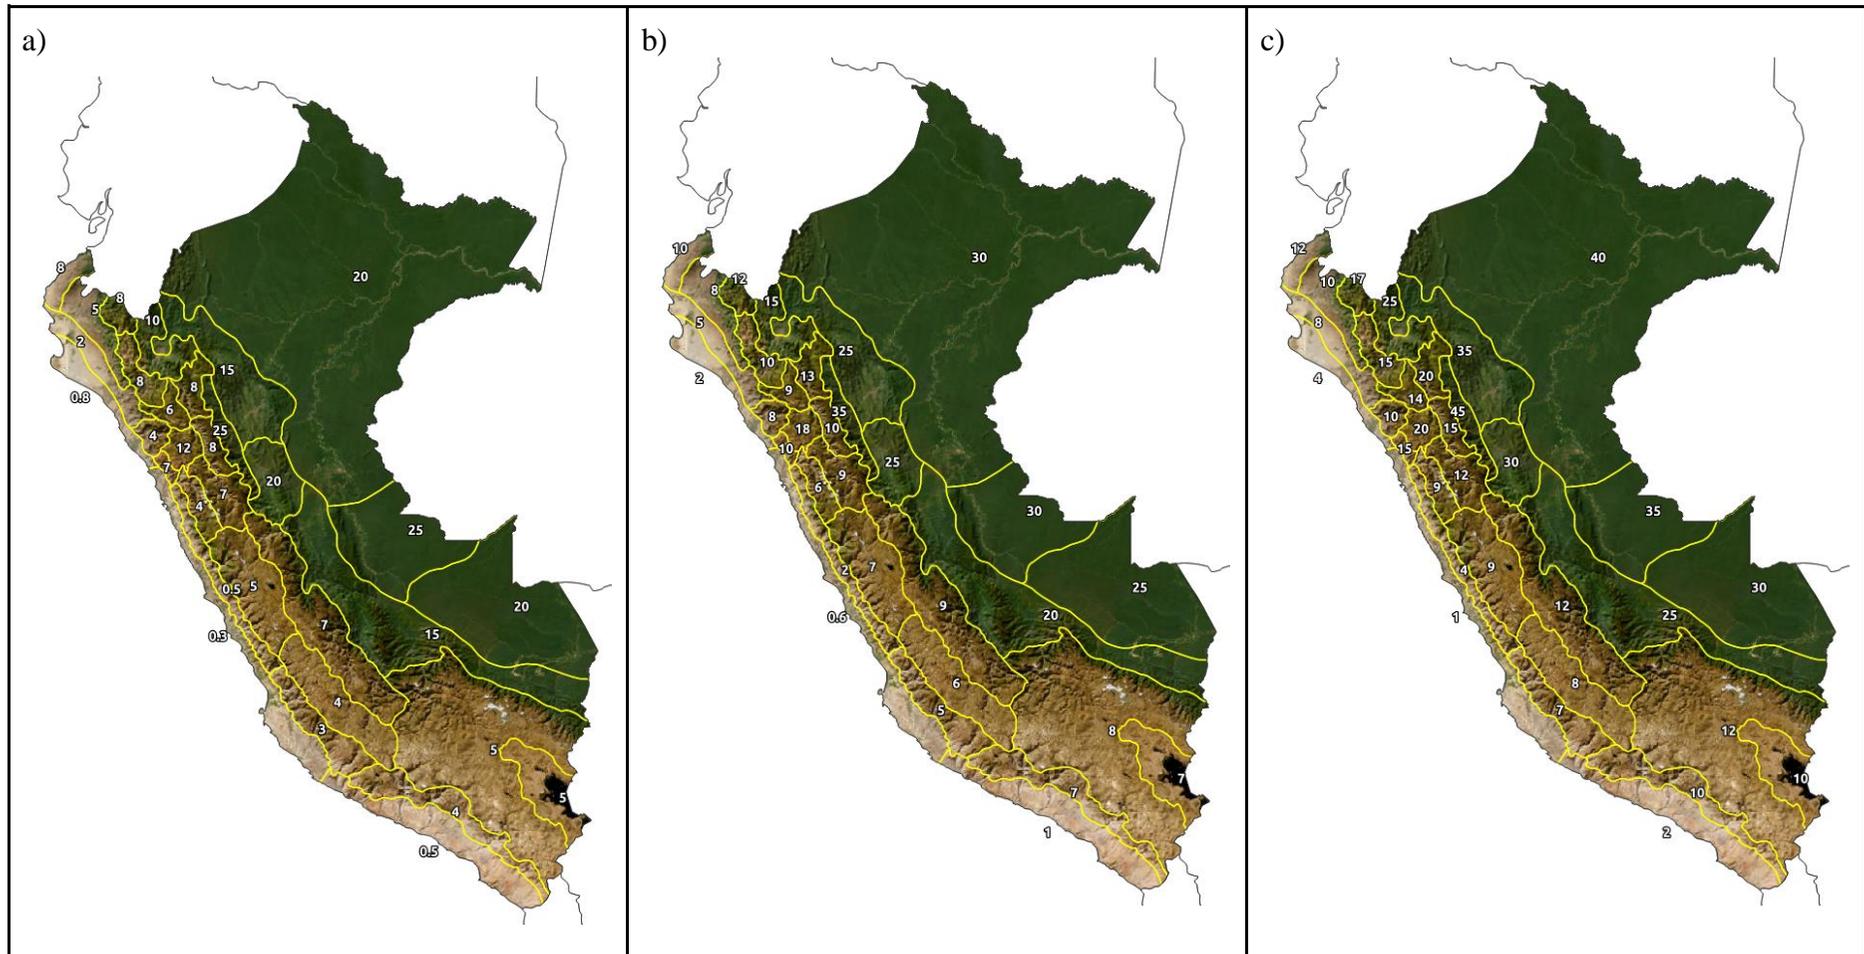


Figura 9. Percentiles empíricos de precipitación horaria
 Percentil empírico 90 (a), 95 (b) y 99 (c) de precipitación horaria.

3.2.6 Pronóstico a Muy Corto Plazo

El algoritmo de nowcasting genera dos tipos de productos, el primero es un *análisis* de la última imagen de satélite procesada, donde se estima la precipitación que puede estar ocurriendo en ese momento; el segundo producto es un *pronóstico* a muy corto plazo de precipitación (pronósticos a 2 horas, conformado por 12 archivos que estiman la precipitación cada 10 minutos). Estos dos productos son actualizados cada 10 minutos con llegada nueva información del GOES-16 (ver [Figura 10](#)). De todas las estimaciones realizadas por el algoritmo de nowcasting, solamente son publicados en la página web del SENAMHI (<https://www.senamhi.gob.pe/?p=reportes-nowcasting>), el análisis y los pronósticos a 60 y a 120 minutos (ver [Figura 11](#)).

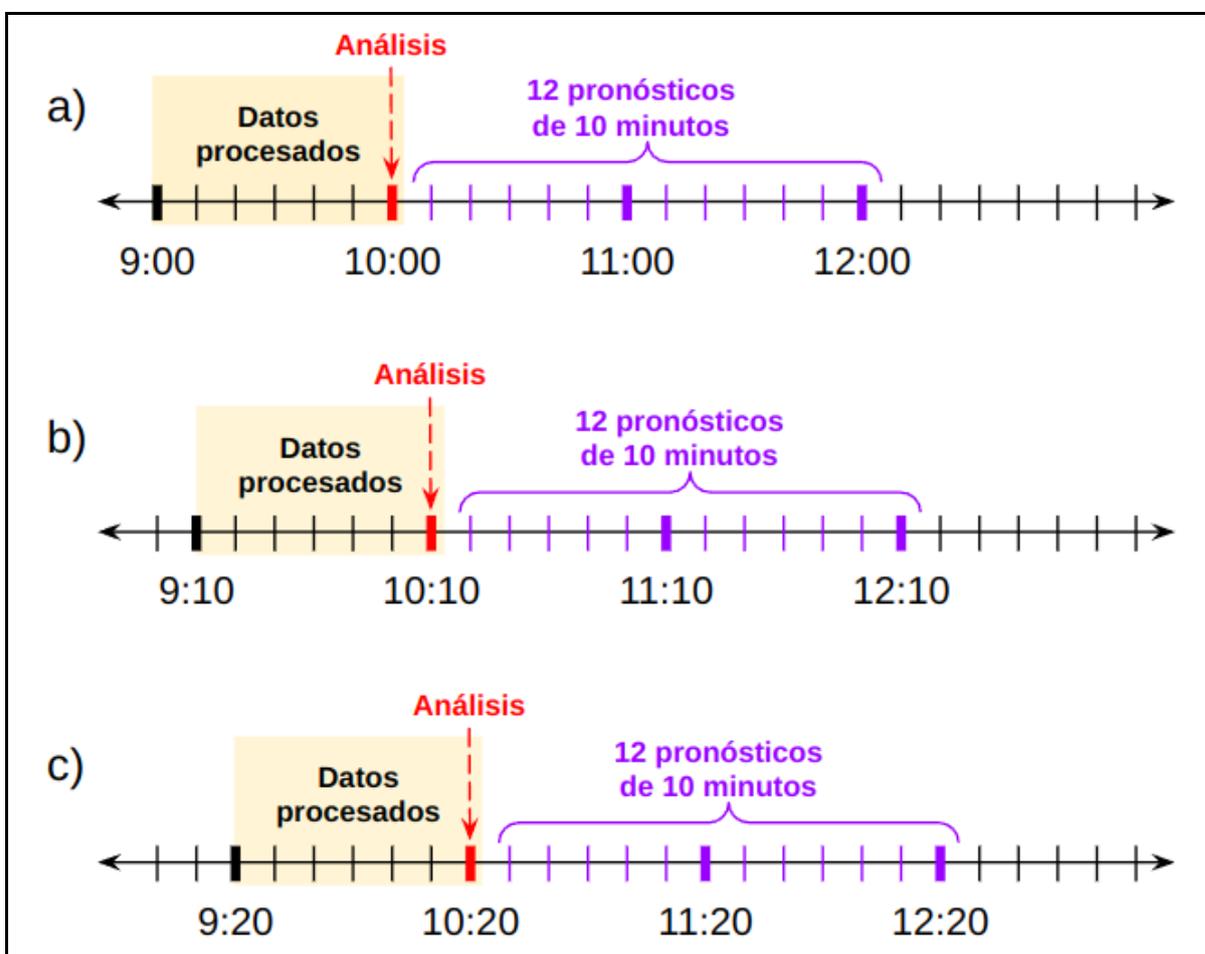


Figura 10. Esquema de generación y actualización de los productos del algoritmo de nowcasting. Representación de la generación del análisis y los pronósticos a 1 hora y 2 horas usando datos del GOES-16 entre las 9:00 y 10:00 horas (a), entre las 9:10 y 10:10 horas (b) y entre las 9:20 y 10:20 horas (c).

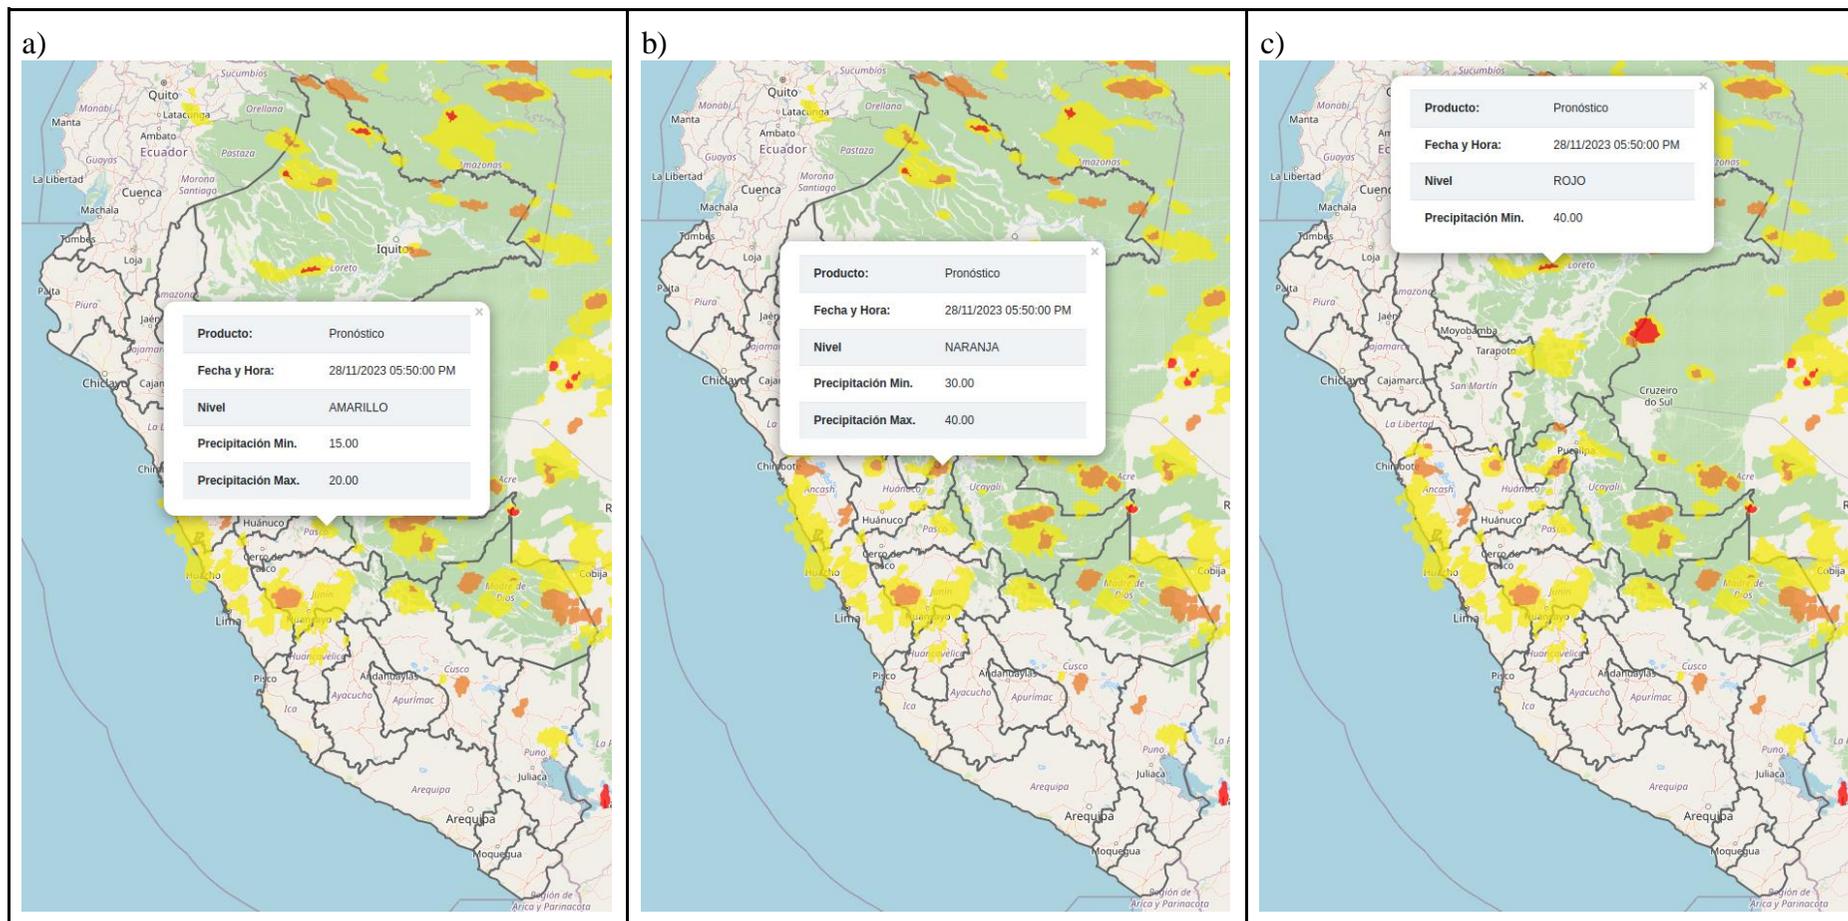


Figura 11. Aviso de nowcasting del SENAMHI

Página web del SENAMHI donde se muestran los avisos de nowcasting conformado por el análisis (a) y los pronósticos a 60 minutos (b) y 120 minutos (c).

3.2.7 Validación de Resultados

Para realizar la validación se crearon pronósticos a 1 y 2 horas a partir de los productos generados por el algoritmo de nowcasting (el análisis y los 12 pronósticos de 10 minutos). Estos pronósticos a 1 y 2 horas muestran el máximo nivel de severidad total que presentaron los archivos de la primera y la segunda hora de pronóstico. En el caso del pronóstico a 1 hora, los archivos utilizados son el análisis y los primero 5 pronósticos, mientras que en el caso del pronóstico a 2 horas se usaron los 6 pronósticos siguientes.

La razón para realizar la validación con pronósticos a 1 y 2 horas se debe a que las estaciones del SENAMHI solo registran la precipitación de forma horaria, por lo cual no se pueden validar los pronósticos de 10 minutos con estos datos.

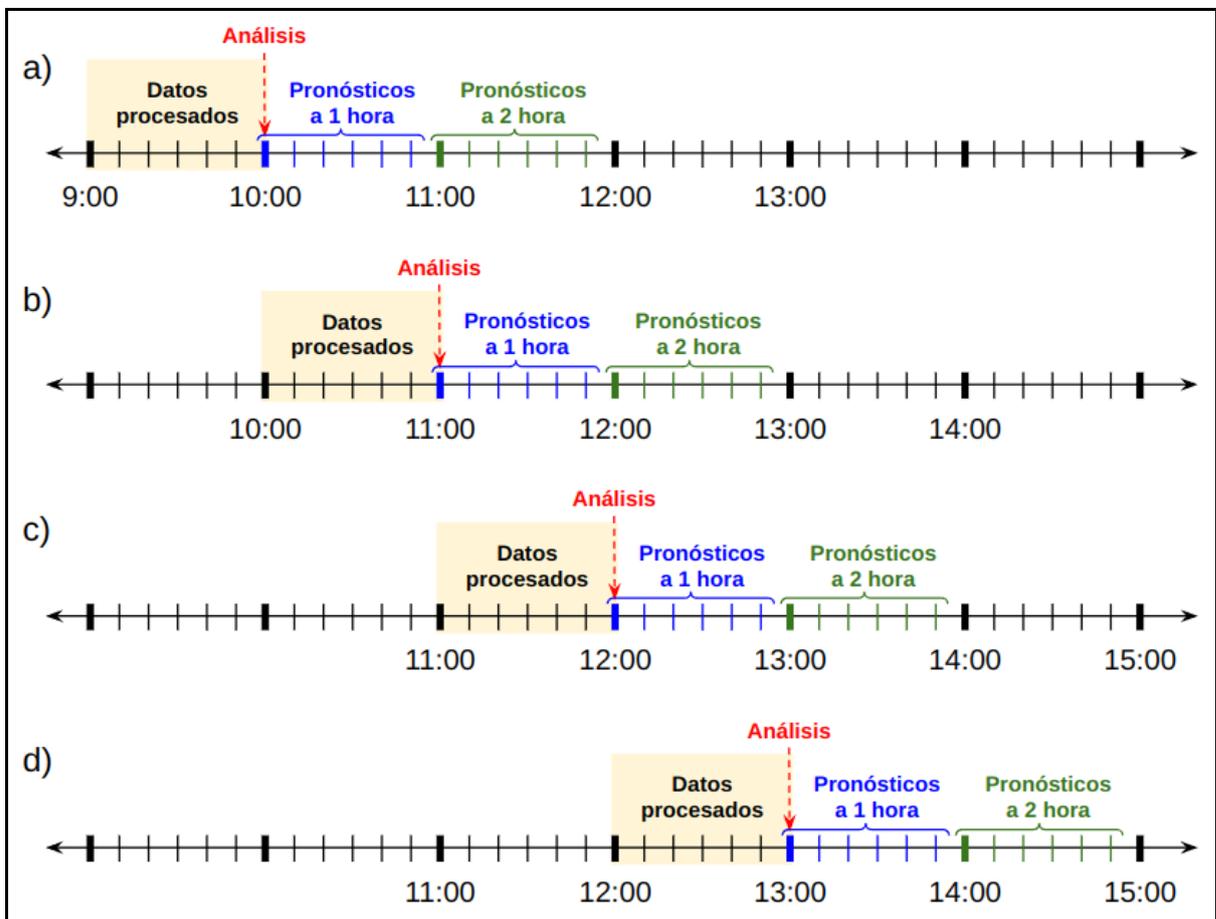


Figura 12. Esquema de selección de datos para la validación

Líneas temporales que representan el esquema de procesamiento horario del algoritmo de nowcasting para generar los pronósticos a 1 hora y 2 horas usando datos entre las 9:00 y 10:00 horas (a), entre las 10:00 y 11:00 horas (b), entre las 11:00 y 12:00 horas (c) y entre las 12:00 y 13:00 horas (d).

Por otro lado, para que los registros horarios de las estaciones del SENAMHI puedan ser comparados con los pronósticos a 1 y 2 horas se tuvo que ejecutar el algoritmo de nowcasting al inicio de cada hora (es decir a las 10:00, a las 11:00, a las 12:00, etc.), para que los

productos generados (un análisis y 12 pronósticos de 10 minutos) cubran por completo las 2 horas que se busca pronosticar. En la Figura 12 se muestra una representación gráfica de este proceso.

La validación de los avisos de nowcasting fue realizada mediante la comparación entre los pronósticos a 1 y 2 horas, y la precipitación registrada por las estaciones del SENAMHI. Esta validación estuvo comprendida por 2 evaluaciones que buscaban:

- 1) determinar la habilidad del algoritmo de nowcasting para pronosticar la ocurrencia de lluvias (sin importar la intensidad)
- 2) determinar la habilidad del algoritmo de nowcasting para pronosticar tiempo severo (lluvias acumuladas en 60 minutos que superan el percentil 90 de precipitación horaria de una localidad)

Para llevar a cabo ambas evaluaciones se utilizó el índice *Probability Of Detection* (POD), que determina el grado de acierto, y el índice *False Alarm Ratio* (FAR), que determina la cantidad de falsas alarmas (WILKS, 2011).

Estos índices son definidos en la Ecuación 5 y la Ecuación 6.

$$POD = \frac{a}{a + c} \dots \quad (Ecuación 5)$$

$$FAR = \frac{b}{a + b} \dots \quad (Ecuación 6)$$

donde “a” representa el número de pronósticos acertados, “b” el número de pronósticos errados (falsas alarmas) y “c” es el número de casos de lluvias no pronosticadas. Los índices POD y FAR presentan valores entre 0 y 1, sin embargo, para facilitar su interpretación, sus unidades fueron multiplicadas por 100% para referirnos a ellas en términos porcentuales. De esta forma, valores de POD de 0% nos indica ningún caso detectado y valores de POD de 100% nos indica que todos los pronósticos fueron acertados. De forma similar, valores de FAR de 0% nos indican que no hubo falsas alarmas y valores de FAR de 100% nos indica que todos los pronósticos fueron falsas alarmas.

Es importante mencionar que los parámetros “a”, “b” y “c” solo fueron calculados en los puntos donde el SENAMHI cuenta con unas estaciones automáticas y que según la evaluación de la validación, estos parámetros son calculados usando diferente criterio. Por

ejemplo, en el caso de la primera evaluación de la validación, “a” representa el número de pronósticos que acertaron la ocurrencia de lluvias mayores que 0 mm, mientras que en el caso de la segunda evaluación “a” representa el número de pronósticos que acertaron la ocurrencia de lluvias que fueron iguales o mayores al percentil 90 de precipitación horaria.

IV. RESULTADOS Y DISCUSIONES

Los resultados de la primera evaluación de la validación, presentados en la Tabla 8, indican que el algoritmo de nowcasting logra detectar el 38.3% de los eventos de lluvias con 1 hora de antecedencia y el 37.33% con 2 horas de antecedencia, mientras que el porcentaje de falsa alarma es de 72.96% y de 73.85% para la primera y segunda hora de pronóstico, respectivamente.

En el caso de la segunda evaluación de la validación, presentada en la Tabla 9, se observa que la habilidad del algoritmo de nowcasting, para detectar lluvias severas, cae hasta el 9.16% y hasta el 9.67% para los pronósticos a 1 hora y 2 horas, respectivamente. Además, se observa que el porcentaje de falsas alarmas asciende hasta un 87.52% en el caso del pronóstico a 1 hora, y hasta un 86.96% en el caso del pronóstico a 2 horas.

Tabla 8: Resultados de la evaluación del algoritmo para identificar lluvias

	1era hora	2da hora
POD	38.30	37.33
FAR	72.96	73.85

Tabla 9: Resultados de la evaluación del algoritmo para identificar lluvias severas

	1era hora	2da hora
POD	9.16	9.67
FAR	87.52	86.93

Estos resultados muestran que los pronósticos de lluvias aún no son lo suficientemente confiables para ser usados como avisos de lluvias a 1 y 2 horas de antecedencia. Teniendo presente que los avisos de nowcasting buscan predecir la ocurrencia de eventos severos para que los tomadores de decisiones realicen sus labores, los altos valores de falsas alarmas ($FAR \geq 86.93\%$) y la baja capacidad de detección ($POD \leq 9.67$) le resta credibilidad a estos avisos.

Si bien estos resultados dejan en evidencia las limitaciones del algoritmo de nowcasting para pronosticar lluvias de moderada a extrema intensidad, el incremento del POD (en más de 25% para ambas horas de pronóstico) y la reducción del FAR (en más de 13% para ambas horas de pronóstico) cuando se pronostica la ocurrencia de lluvias (cualquier tipo de lluvias mayor que 0 mm), nos sugiere que el algoritmo de nowcasting tiene una mayor habilidad para pronosticar lluvias ligeras que lluvias de moderada a extrema intensidad. Teniendo presente que en las imágenes de satélite, las lluvias más intensas muestran características más severas (como toques de nubes más frías y variaciones más abruptas de la TB) que las lluvias ligeras, su identificación debería ser más fácil, sin embargo, los resultados muestran que a pesar de estas características, el algoritmo de nowcasting tiene dificultades para pronosticarlas. Este comportamiento podría deberse a diversos factores, entre ellos, el uso de umbrales de TB y de $\Delta TB_{min10min}$ inadecuados para identificar este tipo de precipitaciones. En ese sentido, el uso de umbrales más precisos podría mejorar los pronósticos de lluvias de moderada a extrema intensidad.

Otro factor que puede estar contribuyendo para tener estos resultados es la ausencia de un modelo que estime la tasa de expansión de los clusters, dentro del algoritmo de nowcasting, lo que causa que los clusters mantengan el mismo tamaño a través de todo el periodo de pronóstico. Este problema afecta a las nubes que se encuentran en etapa de desarrollo porque mantiene su tamaño pequeño a través de todo el periodo de pronóstico, pudiendo ser esta una de las razones que expliquen los bajos valores de POD. Al mismo tiempo, las nubes que se encuentran en etapa de disipación también se ven afectadas por este problema ya que su tamaño, el cual debería disminuir con el tiempo, se mantiene constante en todo el periodo de pronóstico, generando alertas en zonas donde no ocurre tiempo severo, pudiendo ser esta la razón por la cual se tienen altos valores de FAR.

Asimismo, los umbrales empíricos de descargas eléctricas usados en la estimación de severidad pueden ser otro factor que esté afectando al desempeño del algoritmo de nowcasting. El hecho de haber definido estos umbrales a partir de eventos de gran actividad eléctrica, los cuales pudieron corresponder a eventos muy severos, pudo haber ocasionado que estos umbrales no estén asociados con lluvias moderadas y/o fuertes sino solo con lluvias muy extremas. Además, el hecho de haber usado estos umbrales en todo el territorio nacional en lugar de usar umbrales regionales, pudo haber perjudicado el desempeño del algoritmo puesto que una lluvia intensa varía de región en región y no está asociada a la misma densidad de descargas eléctricas. Un caso similar ocurre con los umbrales de precipitación

horaria que están asociados con los niveles de severidad total. Estos umbrales han sido establecidos de forma empírica al carecer de estadísticas de percentiles horarios, pudiendo ser muy diferentes a los valores que se obtendrían de forma estadística.

Finalmente, el hecho de realizar la validación solo en los puntos donde se ubican las estaciones del SENAMHI, en lugar de realizar la evaluación sobre toda la región pronosticada, pudo haber afectado a los índices POD y FAR al reducir la cantidad de casos evaluados. De esta forma pudieron haber quedado fuera de la estadística aquellos puntos donde el pronóstico fue más certero pero que no hubieron estaciones meteorológicas que lo registre. Este problema puede tener una mayor influencia en los resultados si se tiene en cuenta la poca cantidad de estaciones del SENAMHI y su distribución poco representativa de las zonas donde se localizan. Sin embargo, así como estos problemas pudieron haber afectado el desempeño del algoritmo, también pueden estar ocultando resultados mucho peores.

V. CONCLUSIONES

Fue posible desarrollar un algoritmo computacional, en python, que genera avisos a muy corto plazo (nowcasting) de tiempo severo a partir de las informaciones del satélite GOES-16.

La validación de los resultados del algoritmo indica que los pronósticos son poco precisos cuando se trata de estimar tiempo severo (POD menor a 9.7% y FAR mayor a 86% para ambos horarios). Mejores resultados fueron obtenidos cuando se evaluó la capacidad del algoritmo para estimar la ocurrencia de lluvia (POD menor a 39% y FAR mayor a 72% en ambos horarios).

VI. RECOMENDACIONES

Incluir en el algoritmo de nowcasting, un modelo que estime la tasa de expansión de los sistemas convectivos para los próximos minutos.

Incluir en la identificación de severidad de los sistemas convectivos, otros parámetros como la diferencia de $10.3 \mu\text{m} - 6.2 \mu\text{m}$, que es capaz de identificar la convección profunda; la diferencia tris-espectral $[(8.5 \mu\text{m} - 11.2 \mu\text{m}) - (11.2 \mu\text{m} - 12.3 \mu\text{m})]$ que permite discriminar el estado físico de los hidrometeoros; y la diferencia de $8.5 \mu\text{m} - 11.2 \mu\text{m}$ que es usada para identificar el tamaño de los cristales de hielo. Estos parámetros al ser capaces de monitorear otros atributos físicos de las nubes, que los ya monitoreados, pueden mejorar las estimaciones del algoritmo de nowcasting.

Realizar el cálculo de los percentiles 90, 95 y 99 de precipitación horaria y reemplazarlos por los percentiles empíricos utilizados para asignar un intervalo de precipitación horaria a las estimaciones de severidad realizadas por el algoritmo de nowcasting.

Establecer relaciones estadísticas entre los parámetros que se utilizarán en la identificación de severidad (densidad de descargas eléctricas, temperatura de brillo, variación de la temperatura de brillo en 10 minutos, y demás parámetros que se piense incorporar) y la precipitación horaria de las estaciones meteorológicas del SENAMHI, para obtener umbrales que identifiquen de forma más precisa la ocurrencia de precipitaciones moderadas, fuertes y extremas.

Realizar la validación de los resultados en toda la región pronosticada en lugar de realizarlo solo en algunos puntos. El empleo de datos grillados de precipitación como el hidroestimador del GOES o del GPM pueden ser algunas alternativas de datos para ser usados en la validación.

VII. REFERENCIAS BIBLIOGRÁFICAS

ABI GOES-R Series. (s.f.). GOES-R.

Recuperado de: <https://www.goes-r.gov/spacesegment/abi.html>

Ackerman, S. A., Smith, W. L., Revercomb, H. E., & Spinhirne, J. D. (1990). The 27–28 October 1986 FIRE IFO cirrus case study: Spectral properties of cirrus clouds in the 8–12 μm window. *Monthly Weather Review*, 118(11), 2377-2388.

Carvalho, L. M., & Jones, C. (2001). A satellite method to identify structural properties of mesoscale convective systems based on the maximum spatial correlation tracking technique (MASCOTTE). *Journal of Applied Meteorology and Climatology*, 40(10), 1683-1701.

Goodman, S. J., Buechler, D. E., Wright, P. D., & Rust, W. D. (1988). Lightning and precipitation history of a microburst-producing storm. *Geophysical research letters*, 15(11), 1185-1188.

Goodman, S. J., Blakeslee, R. J., Koshak, W. J., Mach, D., Bailey, J., Buechler, D., ... & Stano, G. (2013). The GOES-R geostationary lightning mapper (GLM). *Atmospheric research*, 125, 34-49.

Ground System GOES-R Series. (s.f.). GOES-R. Recuperado el 11 de julio de 2023, de <https://www.goes-r.gov/ground/overview.html>

Laurent, H., Machado, L. A., Morales, C. A., & Durieux, L. (2002). Characteristics of the Amazonian mesoscale convective systems observed from satellite and radar during the WETAMC/LBA experiment. *Journal of Geophysical Research: Atmospheres*, 107(D20), LBA-21.

Machado, L. A. T., & Laurent, H. (2004). The convective system area expansion over Amazonia and its relationships with convective system life duration and high-level wind divergence. *Monthly weather review*, 132(3), 714-725.

- Mecikalski, J. R., & Bedka, K. M. (2006). Forecasting convective initiation by monitoring the evolution of moving cumulus in daytime GOES imagery. *Monthly Weather Review*, 134(1), 49-78.
- Mecikalski, J. R., Bedka, K. M., Paech, S. J., & Litten, L. A. (2008). A statistical evaluation of GOES cloud-top properties for nowcasting convective initiation. *Monthly Weather Review*, 136(12), 4899-4914.
- Mecikalski, J. R., Li, X., Carey, L. D., McCaul, E. W., & Coleman, T. A. (2013). Regional comparison of GOES cloud-top properties and radar characteristics in advance of first-flash lightning initiation. *Monthly weather review*, 141(1), 55-74.
- Mission Overview GOES-R Series. (s.f.). GOES-R. Recuperado el 11 de julio de 2023, de <http://www.goes-r.gov/mission/mission.html>
- Ribeiro, B. Z., Machado, L. A., Huamán Ch, J. H., Biscaro, T. S., Freitas, E. D., Mozer, K. W., & Goodman, S. J. (2019). An evaluation of the GOES-16 rapid scan for nowcasting in southeastern Brazil: analysis of a severe hailstorm case. *Weather and Forecasting*, 34(6), 1829-1848.
- Roberts, R. D., & Rutledge, S. (2003). Nowcasting storm initiation and growth using GOES-8 and WSR-88D data. *Weather and Forecasting*, 18(4), 562-584.
- Rudlosky, S. D., Goodman, S. J., Virts, K. S., & Bruning, E. C. (2019). Initial geostationary lightning mapper observations. *Geophysical Research Letters*, 46(2), 1097-1104.
- Rudlosky, S. D., & Virts, K. S. (2021). Dual geostationary lightning mapper observations. *Monthly Weather Review*, 149(4), 979-998.
- Schmit, T. J., Gunshor, M. M., Menzel, W. P., Gurka, J. J., Li, J., & Bachmeier, A. S. (2005). Introducing the next-generation Advanced Baseline Imager on GOES-R. *Bulletin of the American Meteorological Society*, 86(8), 1079-1096.
- Schmit, T. J., Griffith, P., Gunshor, M. M., Daniels, J. M., Goodman, S. J., & Lebar, W. J. (2017). A closer look at the ABI on the GOES-R series. *Bulletin of the American Meteorological Society*, 98(4), 681-698.
- Strabala, K. I., Ackerman, S. A., & Menzel, W. P. (1994). Cloud Properties inferred from 8 12- μ m Data. *Journal of Applied Meteorology and Climatology*, 33(2), 212-229.

- Vila, D. A., Machado, L. A. T., Laurent, H., & Velasco, I. (2008). Forecast and Tracking the Evolution of Cloud Clusters (ForTraCC) using satellite infrared imagery: Methodology and validation. *Weather and Forecasting*, 23(2), 233-245.
- Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences* (Vol. 100). Academic press.
- WMO OSCAR | Satellite: GOES-16. (2023, 13 de marzo). WMO OSCAR. Recuperado de https://space.oscar.wmo.int/satellites/view/goes_16