



UNIVERSIDAD NACIONAL DE CÓRDOBA
FACULTAD DE ASTRONOMÍA, MATEMÁTICA, FÍSICA Y COMPUTACIÓN
TESIS DE LICENCIATURA EN FÍSICA

DETECCIÓN Y CLASIFICACIÓN DE PRECIPITACIONES EN SUDAMÉRICA MEDIANTE IMÁGENES SATELITALES Y TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Autor	Directores
Federico Andelsman	Dr. Sergio Masuelli
	Dr. Francisco Tamarit

Córdoba - Diciembre 2022

Esta obra está bajo una licencia Creative Commons “Atribución-
NoComercial-CompartirIgual 4.0 Internacional”.



Agradecimientos

A mis amigos de la carrera: Fabri, Pablo, Lara y Facu, por acompañarnos mutuamente en esta locura que es estudiar Física.

A Sergio por la ayuda constante y a Pancho por sus consejos siempre necesarios.

A mis viejos, por darnos a mis hermanos y a mí el impulso y las herramientas para hacer lo que nos dispongamos.

A FAMAFA y a todos los que la integran, porque me han hecho crecer tanto en los éxitos como en los tropiezos.

Resumen

El estudio del evento de precipitación es una de las áreas de mayor interés en las ciencias atmosféricas por su impacto en la vida cotidiana y en su proyección hacia el cambio climático. En este trabajo se aborda el problema de la detección y clasificación de precipitaciones por intensidades a partir de información satelital y métodos provenientes del aprendizaje automático. Se ha elegido como área de estudio a una porción de Sudamérica durante el mes de enero de 2021. El estudio se centra a su vez en el análisis del producto de Estimaciones Cuantitativas de Precipitaciones (QPE del inglés [1]), del satélite GOES-16.

Se entrenó una red neuronal convolucional llamada Cloud-Net [2], con el fin de detectar píxeles de lluvia o clasificarlos por umbrales de intensidades, teniendo como entrada las imágenes multiespectrales de GOES-16 y como datos de etiqueta al producto QPE. A su vez, se probaron distintas funciones de pérdida para la clasificación binaria y multicategoría. En paralelo, se compararon algunos de los resultados con los del algoritmo XGBoost [3].

Se obtuvieron buenos resultados con la red Cloud-Net, en especial para las categorías extremas de píxeles sin lluvia (99% de precisión) y de lluvia mayor a 30 mm/h (hasta 93% de precisión), pero tiene dificultades para distinguir entre algunas categorías intermedias. Al compararlo con XGBoost, Cloud-Net tiene un mejor desempeño para identificar las ubicaciones de lluvias más dispersas. Por su parte, XGBoost sólo obtiene mejores resultados con las lluvias torrenciales, distinguiéndolas con una precisión del 96%. Finalmente, los dos algoritmos tienen una tendencia a subestimar respecto a las intensidades de lluvia provistas por el algoritmo QPE.

Abstract

The study of precipitation is one of the areas of most interest in the atmospheric sciences and with the most impact on our everyday life and on climate change projections. In this project, satellite information and Machine Learning methods are used to treat the detection and classification of precipitation. We have chosen as our area of study a portion of South America during the month of January 2021. We also focus our study on the analysis of the Quantitative Precipitation Estimation product (QPE) of the GOES-16 satellite.

A convolutional neural network called Cloud-Net[2] was trained to detect or classify pixels by rainfall intensities. The QPE product was used as label data and multispectral images of the GOES-16 satellite were used as input. Meanwhile, different loss functions were tested and the multiclass results were compared to those obtained by the XGBoost[3] algorithm.

Cloud-Net performs very well in the extreme classes of No Rain pixels (99 % precision) and torrential rain over 30 mm/h (up to 93 % precision), but it has difficulties distinguishing between some of the intermediate classes. When compared to XGBoost, Cloud-Net has a better performance identifying scattered rain and XGBoost only classifies torrential rain better (96 % precision). Finally, both algorithms tend to underestimate rain intensities in comparison to the QPE algorithm.

Índice general

Agradecimientos	1
Resumen	2
Abstract	3
Acrónimos y Abreviaturas	11
1. Introducción	12
1.1. Objetivos	13
2. Marco Teórico	14
2.1. Generalidades de la Atmósfera	14
2.1.1. Partes de la Atmósfera	14
2.1.2. Presión vs Temperatura	16
2.1.3. El Agua en la Atmósfera	16
2.2. La Teledetección Satelital	24
2.2.1. Espectro Electromagnético	25
2.2.2. Interacción de la radiación con la materia	26
2.2.3. Radiación de cuerpo negro	29
2.2.4. Transferencia Radiativa en Atmósferas Planetarias	31
2.2.5. Introducción a los Satélites Artificiales	33
2.2.6. Señales Geofísicas	34
2.2.7. Radiómetros y Formación de Imágenes	35
2.2.8. Visualización de las imágenes satelitales	37
2.2.9. Satélite GOES-16	38
2.3. Clasificación de Imágenes	41
2.3.1. Algunos Principios básicos del aprendizaje automático	41
2.3.2. Nociones de Redes Neuronales	43
2.3.3. Deep Learning	47
2.3.4. Redes Neuronales Convolucionales	48
2.3.5. Arquitectura de la Red Neuronal Cloud-Net	50
2.3.6. Otros Métodos Posibles: XGBoost	53

3. Metodología	56
3.1. Base de datos	56
3.1.1. Bandas empleadas	56
3.1.2. El producto QPE	57
3.1.3. Elección geográfica y temporal del objeto de estudio	59
3.1.4. Procesamiento previo de los datos	60
3.1.5. Información del Servicio Meteorológico Nacional Argentino	63
3.2. Funciones de pérdida	63
3.2.1. Dice Loss	63
3.2.2. Tversky Loss	64
3.2.3. Categorical Cross Entropy Loss	64
3.2.4. Focal Loss	65
3.3. Resto de Hiperparámetros	65
3.3.1. Red Cloud-Net	65
3.3.2. XGBoost	66
3.4. Métricas	66
3.4.1. Exactitud	67
3.4.2. Matriz de Confusión	67
3.4.3. Distancia de Hamming	68
3.5. Software y Hardware	69
4. Resultados	70
4.1. Abordaje Inicial del QPE	70
4.1.1. Análisis Temporal de las Precipitaciones	70
4.1.2. Análisis Geográfico de las Precipitaciones	73
4.1.3. Comparaciones contra productos visuales estándar de ABI	75
4.1.4. Comparación del QPE con información de suelo	77
4.2. Uso de Cloud-Net y XGBoost	79
4.2.1. Clasificación Binaria: Lluvia vs No Lluvia	79
4.2.2. Clasificación No Binaria	82
5. Conclusiones	90
5.1. Continuaciones del estudio	91
Apéndice	93
Reportes de Clasificación	93
Distribuciones Temperaturas de Brillo	94
Histogramas de Hamming	97
Agregado Información de Pluviómetros de Chaco	98

Índice de figuras

2.1. Partes de la atmósfera según Iribarne y Cho	15
2.2. Diagrama P-T del agua, imagen extraída de Carleton College [4].	17
2.3. Curva SVP (sólida) y curva de presión del vapor para una parcela de aire con vapor de agua que sube (puntos)	19
2.4. Diagrama esquemático de G como función del radio de la gota para $HR = e/e_s = 90\%$ y 110%	21
2.5. Humedad Relativa en el equilibrio inestable como función del radio a 5°C	22
2.6. Fuentes y sumideros de aerosoles en la superficie terrestre	23
2.7. Distintos tipos de Nubes	24
2.8. Diagrama de la radiación electromagnética	25
2.9. Diagrama del espectro electromagnético	26
2.10. Pozo de Potencial Infinito	28
2.11. Diagrama de la emisión y absorción de un fotón (Ilcev)	28
2.12. Radiación teórica de cuerpo negro para 5250°C (curva gris) junto a radiación solar al tope de la atmósfera (amarillo) y radiación a nivel del mar (naranja) [5]	30
2.13. Extinción de un haz incidente por una capa infinitesimal de la atmósfera (Wallace)	31
2.14. Ilustración de los satélites GEO y LEO [6]	33
2.15. Ilustración de las señales que llegan a los sensores espaciales [7]	35
2.16. Parámetros espaciales de la teledetección satelital [8]	36
2.17. Sistema de coordenadas cartesiano para RGB [9]	38
2.18. Satélite GOES-16 con sus instrumentos a bordo, incluyendo el ABI	38
2.19. Grilla de productos L1B o L2, donde n es la cantidad total de píxeles que contiene la imagen. Para el caso de un producto <i>Full Disk</i> , la resolución espacial de 2 km tiene $n=5424$; si es de 1 km, $n=10828$ y si es de 0.5 km, $n=21696$	40
2.20. Ejemplo de Mapa Temático: Clasificación de suelos con Redes Neuronales en Argelia [10]	43
2.21. Modelo Computacional de la Neurona de McCulloch-Pitts [11]	44
2.22. Arquitectura del Perceptrón Multicapa [12]	45
2.23. Efecto de la tasa de aprendizaje en el entrenamiento del modelo	46
2.24. Ejemplos de funciones de activación [13]	47
2.25. Diagrama de la convolución en imágenes	49

2.26. Operaciones de Max Pooling y Average Pooling	49
2.27. Esquema de la red Cloud-Net	50
2.28. Ejemplo de aplicación de la Convolución Transpuesta	51
2.29. Ejemplo de Max Unpooling	51
2.30. Arquitectura del AutoEncoder [14]	52
2.31. Visualización de la convolución 1x1 para un input de dimensiones 64x64x192 y un output de dimensiones 64x64x1	53
2.32. Ejemplo simple de Árbol de Decisión para salir de la casa (Decisión Binaria) [15]	54
2.33. Diagrama de Flujo de Gradient Boosting [16]	55
3.1. Diagrama de flujo del algoritmo QPE	58
3.2. Recorte Total elegido para la inserción en la red	60
3.3. Muestra de sobrecargas en el total de la región de análisis.	61
3.4. Visualización de una Matriz de Confusión binaria	67
4.1. Diferencia entre número de píxeles de Lluvia y de No Lluvia, 01/01/2021.	71
4.2. Diferencia entre número de píxeles de las intensidades de Lluvia, 01/01/2021.	71
4.3. Total de píxeles de lluvia por imagen, 04/01/2021.	72
4.4. Las 25 regiones de análisis	73
4.5. Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 6 (Costa Pacífico de Atacama).	74
4.6. Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 5 (Mato Grosso).	74
4.7. Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 18 (Centro de Argentina).	75
4.8. (a) Producto de Microfísica, con combinaciones de las bandas 3,7 y 13, (b) Producto QPE a las 17:10 UTC del 16/01 en la región 13	75
4.9. Producto de Convectividad, con combinaciones de las bandas 2, 5, 7, 8, 10 y 13	76
4.10. (a) Producto QPE a las 16:40 en la región 13, (b) Producto QPE a las 17:40 en la región 13	77
4.11. Lluvia acumulada desde las 9 ART del día 16/01/2021 hasta las 9 ART del día 17/01/2021. Los puntos corresponden a la información de los pluviómetros y el mapa de colores a la información del QPE	78
4.12. (a) Dice Loss vs Epochs para el entrenamiento con Dice Loss, (b) Dice Loss vs Epochs para el entrenamiento con Tversky Loss.	79
4.13. Matriz de confusión con (a) Dice Loss y (b) Tversky Loss.	80
4.14. Visualización espacial de los resultados de la red Cloud-Net para las 17:10 UTC, 16/01/2021, Región 13 (a) Etiqueta QPE, (b) Predicción con Dice Loss, (c) Predicción con Tversky Loss.	81
4.15. Reporte de Clasificación de Cloud-Net con Dice Loss	81

4.16. (a) Cross Entropy vs Epochs para el primer entrenamiento con 3 categorías, (b) Focal Loss vs Epochs para el segundo entrenamiento con 3 categorías.	82
4.17. Matriz de confusión para 3 categorías con (a) Cloud-Net y Cross Entropy, (b) Cloud-Net y Focal Loss, (c) XGBoost	83
4.18. (a) Etiqueta de Test (QPE) y visualización de predicciones para 3 categorías, para las 17:10 UTC, 16/01/2021 en la región 13, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost	84
4.19. (a) Cross Entropy vs Epochs para el primer entrenamiento con 3 categorías, (b) Focal Loss vs Epochs para el segundo entrenamiento con 6 categorías.	85
4.20. Matriz de confusión para 6 categorías con (a) Cloud-Net y Cross Entropy, (b) Cloud-Net y Focal Loss, (c) XGBoost	86
4.21. (a) Etiqueta de Test (QPE) y visualización de predicciones para 6 categorías, para las 17:10 UTC, 16/01/2021 en la región 13, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost	87
4.22. (a) Data Real y visualización de predicciones para 6 categorías, en ubicación de lluvias intensas, para las 23:30 UTC, 16/01/2021 en la región 8, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost	88
4.23. (a) Histograma de distancias entre la predicción y la etiqueta real, sin el módulo y sin incluir el valor 0, (b) Histograma de distancias entre la predicción y la etiqueta real, con el módulo y en escala logarítmica. Ambos gráficos corresponden a Cloud-Net con Focal Loss.	89
5.1. Reporte de Clasificación de Cloud-Net con Dice Loss	93
5.2. Reporte de Clasificación de Cloud-Net con Tversky Loss	93
5.3. Reporte de Clasificación de Cloud-Net con Cross Entropy y 3 Categorías	93
5.4. Reporte de Clasificación de Cloud-Net con Focal Loss y 3 Categorías	93
5.5. Reporte de Clasificación con XGBoost y 3 Categorías	94
5.6. Reporte de Clasificación de Cloud-Net con Cross Entropy y 6 Categorías	94
5.7. Reporte de Clasificación de Cloud-Net con Focal Loss y 6 Categorías	94
5.8. Reporte de Clasificación con XGBoost y 6 Categorías	94
5.9. Distribuciones de Temperaturas de Brillo de la Banda 8 para las 6 categorías de lluvia	95
5.10. Distribuciones de Temperaturas de Brillo de la Banda 15 para las 6 categorías de lluvia	96
5.11. (a y c) Histograma de distancias entre la predicción y la etiqueta real, sin el módulo y sin incluir el valor 0, (b y d) Histograma de distancias entre la predicción y la etiqueta real, con el módulo y en escala logarítmica. (a y b) corresponden a Cloud-Net con Cross Entropy y (c y d) corresponden a XGBoost.	97

5.12. Zoom en la región de mucha precipitación. Lluvia recolectada a las 7 ART del día 17/01/2021. Los puntos rojos y blancos corresponden a la información de los pluviómetros y el mapa de colores a la información del QPE 98

Índice de cuadros

2.1. Tipos de Nubes y altura correspondiente en la atmósfera	24
2.2. Resumen de longitudes de onda, resolución y usos de las bandas de ABI	39
3.1. Clases de píxeles provistas por L0	59
3.2. Categorías por intensidades de lluvia de píxel	62
3.3. Número de contribuciones al entrenamiento de clasificación binaria por grupo . .	63
4.1. Combinaciones de las bandas empleadas para los productos RGB	76

Acrónimos y Abreviaturas

ABI	Advanced Baseline Imager
Ac	Alto cumulus
ART	Hora de Argentina
As	Altostrato
Cb	Cumulonimbus
Cc	Cirrocumulus
Ci	Cirrus
Cs	Cirrostratus
Cu	Cumulus
DN	Digital Numbers
FOV	Field of View
GEO	Geosynchronous Equatorial Orbit
GIFOV	Ground Instantaneous Field of View
GOES-16	Geostationary Operational Environmental Satellite - 16
IIFOV	Instantaneous Field of View
IR	Infrared
L0	Level 0
L1A	Level 1 A
L1B	Level 1 B
L2	Level 2
LEO	Low Earth Orbit
MEO	Medium Earth Orbit
MW	Microwave
NetCDF	Network Common Data Form
NIR	Near Infrared
NOAA	National Oceanic and Atmospheric Administration
Ns	Nimbostrato
PEO	Polar Earth Orbit
QPE	Quantitative Precipitation Estimation
RGB	Red Green Blue
Sc	Stratocumulus
SVP	Presión de Saturación de Vapor
St	Strato
UTC	Universal Time Convention
Vis	Visible
XGBoost	eXtreme Gradient Boosting

Capítulo 1

Introducción

La variabilidad de las precipitaciones en distintas escalas espacio-temporales afectan nuestra vida y la naturaleza misma del clima. La estimación de precipitaciones en la superficie terrestre es importante en términos científicos (p.ej., para la mejora de modelos hidrológicos), sociales (p.ej., en el monitoreo de enfermedades transmitidas por el agua) y económicos (p.ej., proyección del rendimiento de cultivos). En estos últimos tiempos se ha verificado una creciente aplicación de métodos provenientes del aprendizaje automático, en particular de redes neuronales, como técnica para la extracción de características relevantes de este fenómeno.

Además, en las últimas décadas las operaciones satelitales han posibilitado la generación de estimaciones de precipitaciones a una escala global. La variedad de sensores a bordo nos permite observaciones regulares de la Tierra y de la atmósfera en un gran rango de longitudes de ondas: visible (Vis), infrarrojo (IR) y microondas (MW). Estos sensores son capaces de detectar distintas bandas espectrales de la radiación electromagnética proveniente de las nubes y a partir de esa información se las puede caracterizar e idear algoritmos para distintos usos [17].

Centramos nuestro estudio en el análisis del producto de Estimaciones Cuantitativas de Precipitaciones (QPE, por sus siglas en inglés) del satélite GOES-16. El algoritmo QPE produce cada 10 minutos una tasa de lluvia en milímetros por hora en una grilla con una escala de 2 km mediante el uso de datos de IR y la calibración con tasas de lluvia provenientes de satélites con información de MW. La zona de estudio elegida para este trabajo se extiende aproximadamente desde los 17° S hasta los 39° S y desde los 49° W hasta los 73° W y contiene los países de Uruguay, Paraguay y partes de Argentina, Brasil, Chile y Bolivia. A su vez, se consideran solamente los primeros 16 días del mes de enero del año 2021.

El trabajo se dividió en dos partes. La primera etapa consistió en la mejora del entendimiento del QPE en sí: se estudiaron los patrones temporales y regionales con gráficos de frecuencia, se verificó visualmente la formación de cúmulos para distintas intensidades de precipitaciones, se obtuvieron distribuciones de temperaturas de brillo para las bandas empleadas y se comparó visualmente con algunos productos RGB de la bibliografía existente [18].

Para la segunda etapa, se llevó a cabo un procesamiento de las imágenes satelitales median-

te la clasificación supervisada de los píxeles (problema de segmentación de imágenes). En ella, se consideran las características estadísticas de los datos, tomando a cada banda espectral como una dimensión física y se generan mapas de probabilidad de pertenencia a una determinada categoría/clase. Existen algoritmos que consideran cada píxel como una muestra independiente (XGBoost funciona así) y otros, como las redes convolucionales, que toman en cuenta la vecindad de cada píxel. En este trabajo se emplea un algoritmo en particular conocido como Cloud-Net[2], una red neuronal convolucional originalmente diseñada para detectar píxeles de nubes, adaptada para la detección o clasificación de píxeles según intensidades de lluvia.

Este trabajo se ve inspirado por el auge del estudio de las precipitaciones en los últimos años con distintos métodos provenientes del aprendizaje automático, tanto con información de satélites [19] [20], radares [21] [22] o mixta [23] [24].

1.1. Objetivos

El objetivo principal de este trabajo es comprobar, tanto de manera numérica como visual, si la red Cloud-Net es capaz de replicar los resultados obtenidos por el algoritmo QPE con las mismas bandas espectrales como entrada.

Como objetivos específicos se propuso:

- Comprender los resultados otorgados por el algoritmo QPE e interpretarlos dentro del contexto de las bandas empleadas del satélite GOES-16 y de la ubicación espacio-temporal en la Tierra.
- Comparar el producto QPE con información de suelo provista por el Servicio Meteorológico Nacional.
- Dividir las precipitaciones por intensidades e identificar la presencia de cúmulos de lluvia. Reconocer anomalías y saturaciones del producto QPE.
- Emplear a Cloud-Net para la clasificación binaria de los píxeles (Lluvia/No Lluvia).
- Aumentar la cantidad de categorías de acuerdo a intensidades, primero pasando por 3 y finalmente por 6, para reproducir los resultados del producto QPE.
- Probar si hay mejora en los resultados al usar distintas funciones de pérdida.
- Comparar los resultados con un algoritmo sin consideración de píxeles vecinos, como XGBoost.

Capítulo 2

Marco Teórico

2.1. Generalidades de la Atmósfera

Para los científicos del clima, la atmósfera de la Tierra es un laboratorio natural en el que múltiples procesos físicos tienen lugar. La atmósfera consiste principalmente de una mezcla de gases sujetos por la gravedad, entre los cuales predominan por volumen el nitrógeno y el oxígeno molecular, además de otros constituyentes menores de gran importancia, como el dióxido de carbono, el vapor de agua y el ozono [25].

Para lograr entender el fenómeno físico de las precipitaciones es necesario tener en cuenta y entender ciertas características del entorno en el cual se produce. Las siguientes secciones consisten de una descripción resumida de las partes de la atmósfera, de la presión en función de la temperatura y del agua contenida en la atmósfera.

2.1.1. Partes de la Atmósfera

La atmósfera tiene su máxima densidad justo por encima de la superficie de la Tierra. A medida que se sube, se torna gradualmente en más “fina” hasta que es indistinguible de los gases interplanetarios. Por este motivo, no existe una definición exacta del límite superior de la atmósfera. A medida que se sube en altura, se puede definir diferentes regiones de acuerdo a la multiplicidad de propiedades y a la gran variedad de fenómenos físicos y químicos que se producen. Vale aclarar que esta clasificación es puramente conceptual y puede diferir de acuerdo al investigador a cargo. Las partes descritas en este trabajo se fundamentan en los cambios de tendencia de temperaturas, provienen del libro de Iribarne y Cho [26] y se pueden visualizar en la figura 2.1. Nuestra descripción teórica se enfocará en la tropósfera, capa en la que suelen encontrarse las nubes donde se generan las lluvias.

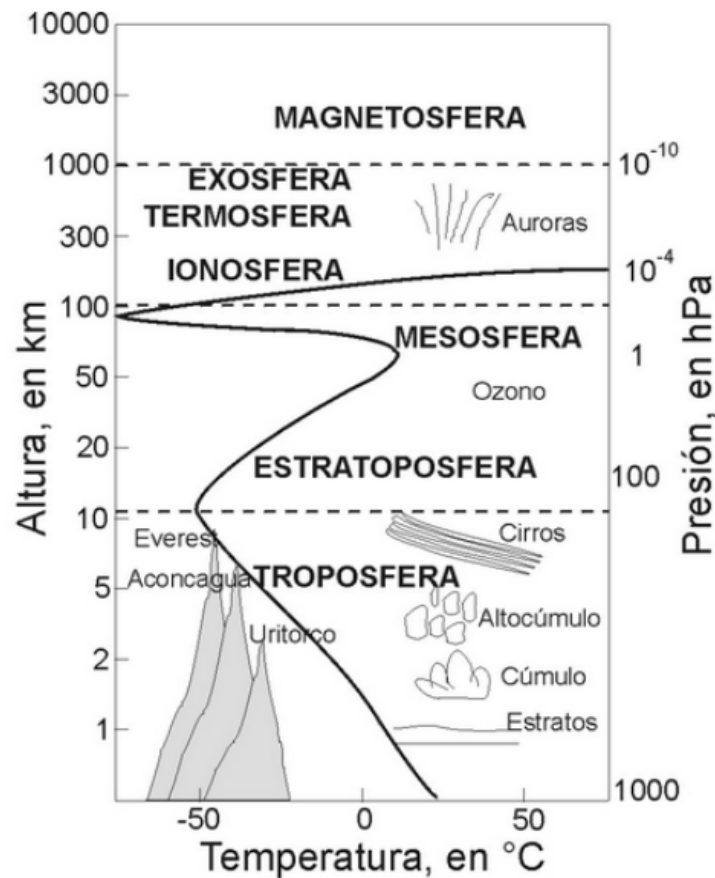


Figura 2.1: Partes de la atmósfera según Iribarne y Cho

La tropósfera es la región más cercana a la superficie terrestre y es la base para los fenómenos de clima que nos afectan. Es científicamente la más conocida y contiene aproximadamente 4/5 del total de la masa de aire. El suelo tiene el máximo de temperatura debido al contacto térmico de la radiación solar con la superficie. A medida que se sube en altura en la tropósfera, la temperatura disminuye linealmente con una tasa de 5°C a 7°C grados por kilómetro. Estos valores varían con el tiempo y de acuerdo al lugar geográfico. Su límite superior está definido por un cambio repentino de este comportamiento, en el que la temperatura deja de decrecer y se mantiene constante o empieza a crecer lentamente. Este límite se denomina tropopausa y también depende del tiempo y de la ubicación geográfica. Su localización es más alta en el Ecuador que en los polos y puede diferir entre 7 y 17 km. La temperatura en la tropopausa para las latitudes medias es de alrededor de -50°C. Los motivos físicos de esta distribución de temperatura en la atmósfera superior no serán analizados en profundidad en este trabajo. Están relacionados a la presencia de ozono absorbente de radiación solar ultravioleta en la estratósfera y de reacciones de ionización y de disociación que se producen en los niveles más altos de la atmósfera [26].

2.1.2. Presión vs Temperatura

Por otro lado, la presión P en cada uno de los niveles está dada por todo el aire que tiene encima por unidad de superficie y está dado por:

$$p(z) = \int_z^{\infty} g(z)\rho(z) dz \quad (2.1)$$

donde g es la aceleración de la gravedad y ρ es la densidad. El cálculo se suele realizar hasta los 20 km, región en la cual g puede considerarse casi constante.

Además, se puede asumir el comportamiento de la atmósfera como el de un conjunto de gases ideales que obedecen la fórmula:

$$p = R_a T \rho \quad (2.2)$$

donde T es la temperatura y $R_a = R/M_m$ es la constante del gas por unidad de masa de aire, dependiente de la muestra de aire en consideración. Mediante argumentos de cumplimiento del balance hidrostático en las diferentes capas de la atmósfera, se llega a la ecuación:

$$\frac{dp}{dz} = -g\rho \quad (2.3)$$

Combinando las ecuaciones 2.2, 2.3 e integrando desde el suelo para arriba, se obtiene la siguiente solución dependiente de la temperatura:

$$p = p_0 \exp\left(-\frac{g}{R_a} \int_0^z \frac{dz'}{T(z')}\right) \quad (2.4)$$

Si uno conoce empíricamente a la temperatura en función de la altura, se puede encontrar la solución exacta de la presión. Una variable importante para este análisis es la tasa de caída $\Gamma = -\frac{dT}{dz}$, que define la disminución de la temperatura con la altura. Tal como se ve en la figura 2.1, $\Gamma > 0$ en la tropósfera y $\Gamma < 0$ en la estratopósfera [25].

2.1.3. El Agua en la Atmósfera

Casi la totalidad de esta sección está basada en el capítulo 2.7 del libro *An Introduction to Atmospheric Physics* de David Andrews [25]. El aire seco está compuesto principalmente de Nitrógeno (78 %) y Oxígeno (21 %), cuyas proporciones son bastante constantes espacialmente, tanto horizontalmente como verticalmente, desde el piso hasta la mesósfera. Por otro lado, el vapor de agua, a pesar de ser un constituyente minoritario (< 3%), juega un rol crucial en los procesos del tiempo y del clima. Es el responsable de las precipitaciones (lluvia y nieve), tiene significancia radiativa y mediante nubes estratosféricas polares colabora con reacciones químicas vinculadas a la disminución del ozono en los polos.

2.1.3.1. La humedad en la atmósfera

En esta sección se consideran las propiedades de la precipitación del vapor de agua, las cuales resultan de que a las temperaturas y presiones terrestres, el agua pasa por cambios de fase entre los estados gaseoso, líquido y sólido.




Figura 2.2: Diagrama P-T del agua, imagen extraída de Carleton College [4].

Requerimos el conocimiento de algunos principios termodinámicos básicos de los cambios de fase y nos enfocamos inicialmente en la transición gas-líquido en el plano de la interfase de la figura 2.2. En esta transición, el vapor está saturado y en equilibrio con el líquido. La pendiente de la curva de presión de saturación del vapor (SVP) está dada por la ecuación de Clausius-Clapeyron:

$$\frac{dP}{dT} = \frac{\delta S}{\delta V} = \frac{L}{T\delta V}, \tag{2.5}$$

donde δS es la entropía ganada como unidad de masa de agua que cambia de líquido a vapor, δV es el aumento del volumen en el mismo proceso y L es el calor latente de vaporización por unidad de masa. Como el volumen específico V_v del vapor de agua es mucho mayor al del líquido y considerando la ley del gas ideal, se puede escribir a la ecuación 2.5 de la siguiente manera:

$$\frac{de_s}{dT} = \frac{Le_s}{R_v T^2}, \tag{2.6}$$

donde R_v es la constante específica del vapor de agua y e_s refiere a la presión de saturación del vapor a lo largo de la curva de coexistencia. Si se asume que L es constante (buena aproximación con temperaturas atmosféricas típicas), la ecuación 2.6 se puede integrar y obtener:

$$e_s(T) = e_s(T_0) \exp\left(\frac{L}{R_V} \left(\frac{1}{T_0} - \frac{1}{T}\right)\right) \quad (2.7)$$

donde T_0 es una temperatura de referencia constante. Consideremos una parcela de aire húmedo de masa unitaria que contiene una masa relativa a la masa total del aire μ de vapor de agua. Si no se produce condensación o evaporación, esta masa relativa se mantiene constante y la presión del vapor e en la parcela satisface:

$$e = \frac{\mu P}{\epsilon} \quad (2.8)$$

donde P es la presión total en el aire y ϵ es el cociente entre la masa molecular del vapor de agua y la masa molecular media del aire húmedo. Si el valor de la presión del vapor de agua e permanece menor a los valores de e_s no se produce la saturación ya que el vapor de agua permanece por debajo de la curva de coexistencia líquido-vapor de la figura 2.2. Si se supone un traslado adiabático de la parcela desde la superficie (a una temperatura inicial T_0 y una presión inicial P_0), entonces la temperatura T de la parcela decae de acuerdo a la siguiente ecuación:

$$T = T_0 \left(\frac{P}{P_0}\right)^\kappa \quad (2.9)$$

donde κ es el cociente entre la constante del gas R_a y el calor específico a presión constante c_p . Con la ayuda de la ecuación 2.8 podemos eliminar la presión P de la parcela para averiguar cómo varía la presión del vapor de agua en función de la temperatura:

$$e_{\text{parcel}}(T) = \frac{\mu P_0}{\epsilon} \left(\frac{T}{T_0}\right)^{1/\kappa} \quad (2.10)$$

Tal como se muestra en la figura 2.3, eventualmente la temperatura de la parcela decae lo suficiente para llegar a la línea de SVP y se produce la saturación. Este valor de presión se denomina nivel de levantamiento de condensación. En la subsección siguiente se hará una breve descripción del proceso de formación de gotas de agua.

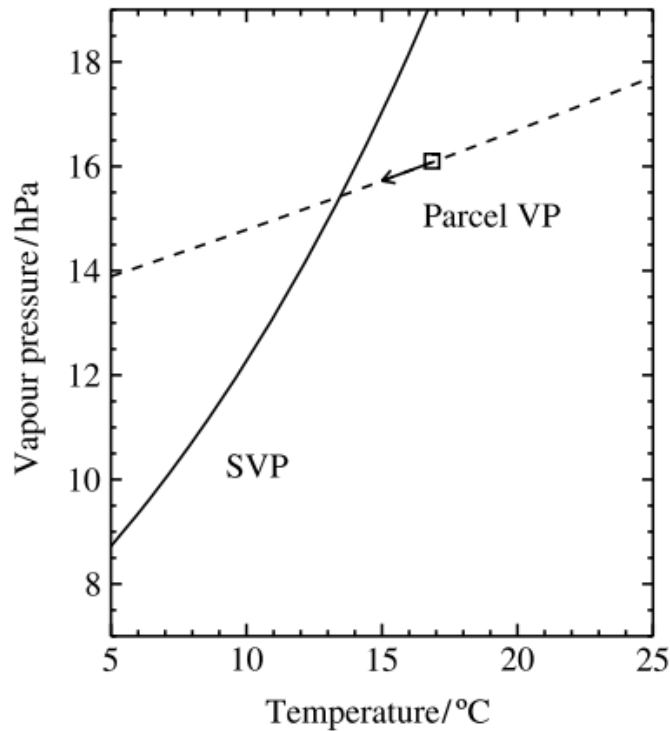


Figura 2.3: Curva SVP (sólida) y curva de presión del vapor para una parcela de aire con vapor de agua que sube (puntos)

2.1.3.2. Formación de Nubes

En la subsección anterior se consideró solamente el caso de una interfaz plana entre el líquido y el vapor. En realidad, las gotitas de agua son aproximadamente esféricas y son necesarios procesos de supersaturación ($e > e_s$) para que las gotas se formen de manera espontánea a partir del vapor de agua. Para incluir efectos de tensión superficial se introduce a la energía libre de Gibbs:

$$G = U - TS + PV \quad , \quad \delta G = -S\delta T + V\delta P \quad (2.11)$$

Consideremos una gota de agua inmersa en vapor de agua, a una presión parcial e y a una temperatura T (se puede ignorar el “aire seco”). Si se supone que el vapor y el líquido no están en equilibrio ($e \neq e_s(T)$), separamos la energía libre de Gibbs por unidad de masa del vapor G_V de la del líquido G_L y variamos δe la presión parcial e a una temperatura constante, se producen los siguientes cambios en las energías libres:

$$\delta G_V = V_V \delta e \quad , \quad \delta G_L = V_L \delta e \quad (2.12)$$

donde V_V y V_L son los volúmenes específicos del vapor y del líquido respectivamente. Por ende:

$$\delta (G_V - G_L) = (V_V - V_L) \delta e \approx V_V \delta e \quad (2.13)$$

El vapor de agua satisface la ley del gas ideal por lo que se puede reemplazar e integrar respecto a una temperatura fija y obtener:

$$G_V(T, e) - G_1(T, e) = R_V T \ln \left(\frac{e}{e_s(T)} \right) \quad (2.14)$$

Si se supone en un momento inicial una masa m_0 de vapor de agua, a presión parcial e y temperatura T , sin una gota de agua presente, la energía de Gibbs total equivale a :

$$G_0 = G_V(T, e)m_0 \quad (2.15)$$

Luego, la gota comienza a condensar a temperatura y presión fija. Si se supone que llega a un radio r , tal que la superficie es $A = 4\pi r^2$ y la masa es $m_1 = \frac{4\pi r^3 \rho_l}{3}$, donde ρ_l es la densidad del líquido y la masa del vapor circundante es m_V . La energía libre de Gibbs del sistema ahora será la suma de las energías libres más una contribución extra (γA) debida a la tensión superficial. Por conservación de la masa y por la ecuación 2.14 se llega a la siguiente ecuación:

$$G - G_0 = -\frac{4}{3}\pi r^3 \rho_l R_V T \ln \left(\frac{e}{e_s(T)} \right) + 4\pi r^2 \gamma \quad , \quad G(a) = G_0 - \beta r^3 + \alpha r^2 \quad (2.16)$$

Se muestra el gráfico de esta función en la figura 2.4 para dos valores de humedad relativa (e/e_s). Lo primero que se puede notar es que para casos de subsaturación ($e \leq e_s(T)$) el logaritmo en la ecuación 2.16 es negativo o nulo, por lo que $\beta \leq 0$ y la curva de $G(r)$ solo tiene un punto crítico en a . En cambio, para el caso de supersaturación ($e \geq e_s(T)$), el logaritmo es positivo, $\beta \geq 0$ y se obtiene el máximo de G a un radio a , dado por:

$$a = \frac{2\alpha}{3\beta} = \frac{2\gamma}{\rho_l R_V T \ln(e/e_s(T))} \quad (2.17)$$

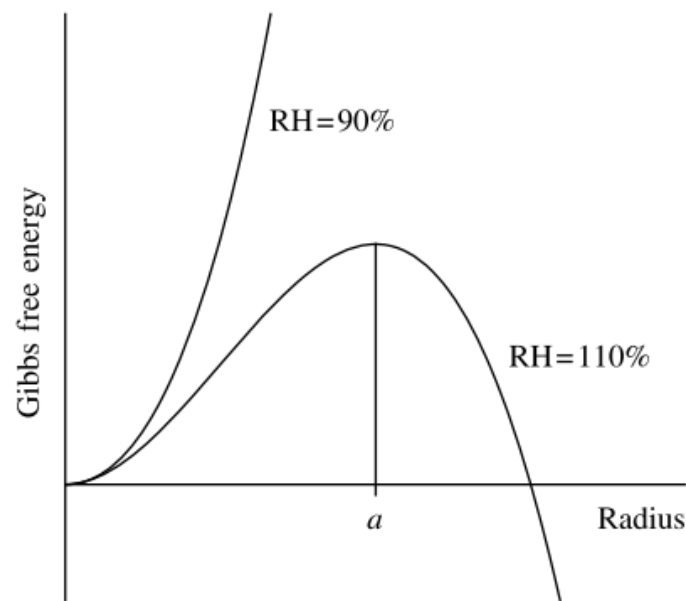


Figura 2.4: Diagrama esquemático de G como función del radio de la gota para $HR = e/e_s = 90\%$ y 110%

Este resultado es conocido como la fórmula de Kelvin. Un resultado termodinámico conocido es que un sistema a temperatura y presión constantes tiende a evolucionar de manera tal que la energía libre de Gibbs llegue a un mínimo. Por otro lado, el radio a obtenido en la ecuación 2.17 corresponde a un equilibrio inestable. Esto implica que la condensación de una pequeña cantidad de vapor de agua aumenta el radio ligeramente y de esta manera la gota sigue creciendo por la condensación. Por otro lado, si se produce algo de evaporación en el radio de equilibrio, la gota comienza a achicarse y termina desapareciendo. Para asegurar la supervivencia de la gota de agua, se necesita que llegue a un radio mayor al radio de equilibrio a que corresponde a la humedad de ambiente relativa. Como la humedad relativa en nubes no suele superar los 101% , de acuerdo a la figura 2.5 se requiere que el radio supere los $0,1\mu m$. Es altamente improbable que se obtenga una gota de este tamaño por la colisión aleatoria de pequeñas gotas, por lo que un proceso más viable es que la gota condense a una partícula líquida o sólida preexistente, conocida como **Núcleo de Condensación de Precipitación**. Nótese también, que el tamaño de la gota es inversamente proporcional a la temperatura del sistema.




Figura 2.5: Humedad Relativa en el equilibrio inestable como función del radio a 5°C

Distintos tipos de partículas en suspensión pueden actuar como núcleos de condensación¹. Es necesario que cumplan dos condiciones: que sean muy pequeñas para que no caigan rápido y que sean hidrofílicas. La suspensión de un conjunto de partículas líquidas o sólidas en un gas es conocida como aerosol y la mayoría proviene de la superficie terrestre, ya sea de fuentes naturales o antropogénicas. Algunos de estos aerosoles son primarios, es decir, son emitidos directamente de la fuente, pero la mayoría consisten de emisiones gaseosas que se convierten en partículas de aerosol por las reacciones químicas en la atmósfera. En la figura 2.6 se observan las posibles fuentes y sumideros para estos aerosoles. El estudio de los núcleos de condensación y de los aerosoles es sumamente importante en el análisis de precipitaciones y en la lucha contra el cambio climático, siendo un área de sumo interés para meteorólogos y científicos de la atmósfera [27] [28].

Desde un punto de vista macroscópico, cuando una masa de aire húmedo se enfría, sea por la presencia de una corriente ascendente (enfriamiento adiabático), por contacto con una superficie fría (niebla) o pasando sobre masa de aire más fría (estratos), se producirá condensación del vapor de agua para formar gotitas a partir de la presencia de los núcleos de condensación adecuados [29].

¹Link fuente de este párrafo: <https://www.e-education.psu.edu/meteo300/node/671>.

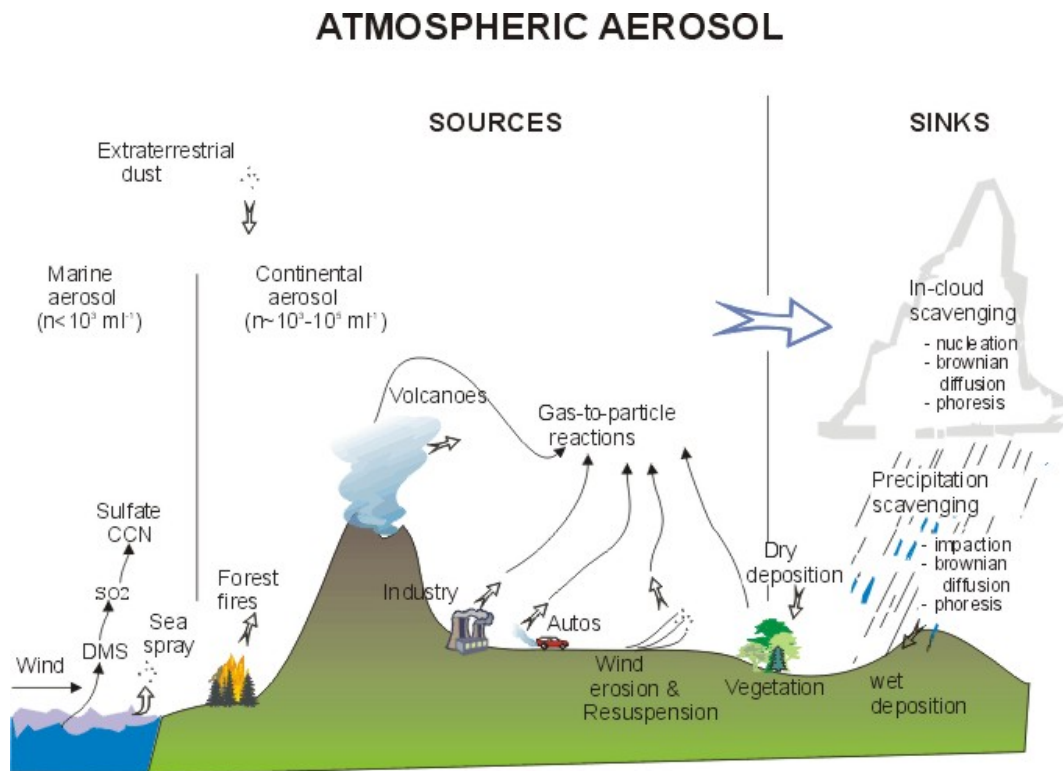


Figura 2.6: Fuentes y sumideros de aerosoles en la superficie terrestre

2.1.3.3. Tipos de Nubes

La Organización Mundial de Meteorología define un hidrometeoro como un objeto que consiste de partículas de agua sólidas o líquidas. Existen 5 tipos de hidrometeoros distintos: partículas suspendidas (niebla o nubes), partículas en caída (precipitación), partículas levantadas por el viento de la superficie terrestre, depósitos de partículas y mangas de agua (embudo que contiene un intenso vórtice o torbellino que ocurre sobre un cuerpo de agua).

Se reconocen diez géneros principales de nubes, los cuales se muestran en la tabla 2.1. Los nombres están compuestos por prefijos y sufijos, los cuales tienen un significado particular [26]:

- Cirrus: la nube consiste de partículas de hielo, aparece solo a niveles altos de la Troposfera donde la temperatura es lo suficientemente baja.
- Strato: nube dispuesta en una capa, sea continua o con cierta estructura.
- Alto: nube que se encuentra en alturas medias de la tropósfera.
- Cumulo: indica una circulación vertical con corrientes ascendentes localizadas.
- Nimbo: indica un tipo de nube que produce precipitación

Cuadro 2.1: Tipos de Nubes y altura correspondiente en la atmósfera

Género	Abreviación	Altura en la atmósfera
Cirrus	Ci	Alto
Cirrocumulus	Cc	Alto
Cirrostratus	Cs	Alto
Alto cumulus	Ac	Media
Altostratus	As	Media
Nimbostratus	Ns	Baja
Stratocumulus	Sc	Baja
Stratus	St	Baja
Cumulus	Cu	Nubes Convectivas
Cumulonimbus	Cb	Nubes Convectivas

En la figura 2.7 se muestran los distintos tipos mencionados. Las nubes de tipo Cumulus y Cumulonimbus son diferentes de las otras dado que tienen un desarrollo vertical considerable sobre un área limitada, es decir, no ocupan un sólo nivel específico o una sólo capa. En particular, las Cumulonimbus (también denominadas nubes de convección profunda) son las más complejas debido a que presentan una gran variedad de hidrometeoros en fase líquida y sólida, desde gotitas a granizos, y esta clase de nubes están asociadas a los eventos más severos como precipitaciones intensas, rayos y tornados.




Figura 2.7: Distintos tipos de Nubes

2.2. La Teledetección Satelital

La teledetección es la acción de obtener información sobre algún objeto que se encuentra distante sin hacer contacto físico con el mismo. Esta es una definición muy general del término,

la cual puede incluir técnicas para el estudio de eventos sísmicos, geomagnéticos o sonares. En este trabajo nos vamos a restringir al entendimiento del uso de la radiación electromagnética captada por una amplia variedad de satélites artificiales de observación terrestre que orbitan el planeta, enviándonos información sobre la atmósfera y la superficie. Las siguientes subsecciones se han redactado con la ayuda de múltiples libros [30] [31] [32] [33].

2.2.1. Espectro Electromagnético

Se puede transferir energía a través de uno de los siguientes procesos [30]:

- **Conducción:** transferencia de energía cinética a través del contacto directo (colisiones) entre átomos o moléculas a velocidades diferentes.
- **Convección:** desplazamiento físico de la materia a través de gases o líquidos.
- **Radiación:** proceso por el cual la energía es trasladada por el espacio o la atmósfera sin la necesidad de un medio, en contraste a los dos métodos anteriores.

En este trabajo nos vamos a enfocar en la radiación electromagnética. Una **onda electromagnética** está compuesta por ondas de campo eléctrico y magnético, cuyos vectores son perpendiculares entre sí y perpendiculares respecto a la dirección de propagación de la onda δ . Se puede caracterizar a la radiación a partir de las intensidades de los campos, de la longitud de onda λ , es decir, la distancia entre los picos del campo eléctrico o magnético, o a través de la frecuencia ν , la tasa a la cual los campos oscilan respecto a un punto en particular. Se puede relacionar a estos dos últimos valores entre sí y con la energía transportada a través de la ecuaciones:

$$\nu = \frac{c}{\lambda} \quad , \quad E = h\nu \quad (2.18)$$

donde h es la constante de Planck y $c \approx 2,998m/s$ es la velocidad de la luz a través del vacío. En la atmósfera, la luz viaja ligeramente más despacio debido a la interacción con las moléculas del aire.




Figura 2.8: Diagrama de la radiación electromagnética

Se entiende por espectro electromagnético a todo el rango de longitudes de onda (o frecuencias) existentes de la radiación electromagnética, siendo los colores de la luz visible sólo una pequeña parte de la misma (ver figura 2.9). Todo objeto tiene un espectro característico de radiación que emite, absorbe o transmite. Para este trabajo será particularmente importante la parte infrarroja (IR). De todos modos, también se comentarán detalles acerca de la importancia de la información de microondas (MW).




Figura 2.9: Diagrama del espectro electromagnético

2.2.2. Interacción de la radiación con la materia

Cuando la radiación incide sobre un medio, que asumiremos por ahora que tiene una superficie plana, la onda electromagnética puede verse alterada por los siguientes procesos:

2.2.2.1. Reflexión

Se pueden tener dos tipos de reflexiones distintas, si la superficie es completamente plana, todos los rayos reflejados viajan en la misma dirección y salen emitidos con el mismo ángulo que el de incidencia. Esta es conocida como reflexión especular. En el caso que la superficie sea rugosa, los rayos reflejados viajan en todas las direcciones. Esta es conocida como reflexión difusa.

2.2.2.2. Transmisión y Refracción

La onda también puede atravesar el medio sin cambiar la dirección o que sea refractada, es decir que cambie su dirección a medida que atraviesa el medio. Las ecuaciones de Fresnel

determinan si una onda es reflejada o transmitida en función del índice de refracción de cada medio y su estado de polarización ². El índice de refracción es un número complejo que se escribe de la siguiente manera:

$$n = n' + in'' \quad (2.19)$$

donde n' describe la transmisión de la onda por el nuevo medio y n'' puede ser considerado un coeficiente de absorción del mismo.

2.2.2.3. Transiciones de Energía

Los fenómenos de absorción y emisión se pueden explicar a través de conceptos básicos de mecánica cuántica. Las moléculas en reposo están caracterizadas por la energía que poseen. El punto clave de la teoría cuántica es que los posibles niveles de energía están descritos en una secuencia discreta E_n , específica de las propiedades espectroscópicas de la molécula. La ilustración más simple para estos niveles discretos de energía es un caso muy conocido para los estudiantes de física: el pozo de potencial. El mismo corresponde a la presencia de un potencial $V(x)$ unidimensional en un intervalo finito $[0,1]$ de la variable espacial x . La función de onda $\psi(x)$ está gobernada por la ecuación de Schrodinger:

$$\frac{-\hbar^2}{2m} \frac{d^2\psi(x)}{dx^2} + V(x)\psi(x) = E\psi(x) \quad (2.20)$$

donde m es la masa de la partícula, E corresponde a la energía de la partícula y \hbar es la constante de Planck. El desplazamiento de la partícula es libre dentro del pozo ($V=0$) pero no puede salir del mismo (Se visualiza en la figura 2.10). La solución para la ecuación 2.20 dentro del pozo con estas condiciones de contorno son de la forma $\psi(x) \sim \sin(x\sqrt{2mE/\hbar^2})$, donde se cumple la relación $2mE/\hbar^2 = n\pi$, siendo n un entero positivo. Es decir, se obtiene un espectro discreto de niveles de energía presentado por la siguiente relación:

$$E_n = n^2 \frac{\hbar^2 \pi^2}{2m} \quad (2.21)$$

²No es el objetivo de este trabajo la explicación de este conjunto de ecuaciones, pero para aquel que esté interesado ver Rees Capítulo 3.2.[31]




Figura 2.10: Pozo de Potencial Infinito

Si se considera una molécula con un nivel de energía E_2 , la emisión de un fotón por parte de esta molécula corresponde a una transición a un nivel más bajo de energía E_1 . Por contrario, la absorción de un fotón implica la transición de E_1 a un nivel de energía más alto E_2 . Lo que nos interesa entender es que la longitud de onda del fotón que interactúa con la molécula está fijada por las transiciones de energía posibles. En la figura 2.11 se muestra una transición entre dos niveles de energía ($E_1 < E_2$). La longitud de onda característica de este proceso se obtiene por la ley de Planck (2da fórmula de la ecuación 2.18), donde E corresponde a la diferencia ΔE entre E_2 y E_1 .




Figura 2.11: Diagrama de la emisión y absorción de un fotón (Ilcev)

2.2.2.4. Scattering

Es un proceso físico mediante el cual la partícula que se encuentra en el camino de la onda electromagnética toma energía continuamente de la onda incidente y la irradia en todas las direcciones. En la atmósfera, las partículas responsables del proceso de scattering van desde moléculas de gas ($\sim 10^{-8}$ cm) a gotas grandes de agua (~ 1 cm). La intensidad relativa del patrón dispersado depende fuertemente de la relación entre el tamaño de la partícula y la longitud de onda incidente. Cuando las partículas son mucho más pequeñas que la longitud de onda incidente, el campo electromagnético se puede aproximar como homogéneo y se emplea la denominada dispersión de Rayleigh. Por lo contrario, para partículas con tamaños comparables

al de la longitud de onda, la aproximación ya no es válida y es necesario llevar a cabo un cálculo más detallado entre el campo electromagnético y la partícula. Este proceso se refiere generalmente como scattering de Mie [30].

Se considera un haz de radiación que pasa por una capa arbitrariamente delgada de la atmósfera. Para cada tipo de molécula de gas o partícula que se encuentra el haz, la intensidad monocromática disminuye con la siguiente ecuación:

$$dI(\lambda) = -I(\lambda)K(\lambda)N\sigma ds \quad (2.22)$$

donde N es el número de partículas por unidad de volumen, σ es la sección eficaz de la partícula, $K(\lambda)$ es la eficiencia de scattering adimensional (se puede describir a la absorción de manera equivalente y aditiva). Es instructivo considerar el caso de scattering por una partícula esférica de radio r en base al parámetro adimensional:

$$x = \frac{2\pi r}{\lambda} \quad (2.23)$$

Partículas con $x \ll 1$ son relativamente ineficientes en el scattering (régimen de Rayleigh). A la hora de trabajar en teledetección, se tiene que tener en cuenta la dependencia de las eficiencias de scattering y absorción $K(\lambda)$ respecto al parámetro x . Por ejemplo, la radiación de IR es fuertemente absorbida por las nubes mientras que la radiación de MW pasa por las nubes con gotas de cientos de micrómetros de radio casi sin scattering. La retrodispersión de la señal por parte de las gotas más grandes revelan posibles regiones con precipitación más intensa [32].

2.2.3. Radiación de cuerpo negro

Muchas leyes fundamentales que gobiernan la absorción y emisión de la radiación electromagnética se basan en el concepto de un cuerpo negro. Este es en su base una idea completamente teórica de un objeto que absorbe toda la radiación incidente, no refleja nada y emite toda la energía con una eficiencia total para todas las longitudes de onda. La ecuación que refleja este comportamiento es [33]:

$$B(\lambda, T) = \frac{2hc^2\lambda^{-5}}{e^{\frac{hc}{\lambda kT}} - 1} \quad (2.24)$$

donde B es la luminosidad espectral, T es la temperatura del cuerpo negro en K, λ es la longitud de onda, k es la constante de Boltzmann, h es la constante de Planck y c es la velocidad de la luz en el vacío. La relación entre la emisión de cuerpo negro y su temperatura se conoce como ley de Planck. Para cualquier temperatura, la ley de Planck da un espectro característico de radiación electromagnética que tiene su pico para una determinada longitud de onda.

La ubicación del pico respecto a la temperatura se describe por la ley de desplazamiento de Wien, la cual indica:

$$\lambda_{\max} = \frac{b}{T} \quad (2.25)$$

donde $b \approx 2,89 * 10^{-3}$ m.K es la constante de desplazamiento de Wien. Otra ley importante es la de Stefan-Boltzmann, en la cual se muestra que la energía emitida para todas las longitudes de onda es directamente proporcional a T^4 :

$$P = \sigma T^4 \quad (2.26)$$

donde P es la potencia emisiva hemisférica total, tiene unidades de $\text{W} \cdot \text{m}^{-2}$ y $\sigma \approx 5,67 * 10^{-8}$ $\text{W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$ es la constante de Stefan-Boltzmann. De hecho, la energía es el área por debajo de la curva de Planck de la figura 2.12. Por ello, a medida que crece la temperatura del cuerpo negro, el desplazamiento del pico a longitudes de onda más cortas son gobernadas por la ley de Wien y el aumento en la altura de la curva se explica por la ley de Stefan-Boltzmann.

Existe otra ley importante, conocida como ley de Kirchhoff, que dice que si la radiación del cuerpo negro es isotrópica entonces la relación ϵ entre radiación emitida y radiación absorbida es la misma para todos los cuerpos negros a una misma temperatura. Esta ley es la base para la definición de la emisividad de un cuerpo ($\epsilon = 1$ para un cuerpo negro y $\epsilon = 0$ para un reflector perfecto).




Figura 2.12: Radiación teórica de cuerpo negro para 5250°C (curva gris) junto a radiación solar al tope de la atmósfera (amarillo) y radiación a nivel del mar (naranja) [5]

Estos modelos teóricos descriptos son extremadamente útiles para el mundo real, ya que son empleados como aproximaciones a cuerpos que tienen poca interacción con el ambiente que los rodea y pueden ser considerados como cuerpos en un estado de equilibrio. Tal como se observa en la figura 2.12, en nuestro sistema Tierra-Atmósfera, se puede ver la radiación teórica de cuerpo negro junto a las ventanas espectrales para la observación de las superficies del tope

de la atmósfera y del mar.

2.2.4. Transferencia Radiativa en Atmósferas Planetarias

La ecuación 2.22 también se puede expresar de la siguiente manera [32]:

$$dI(\lambda) = -I(\lambda)\rho rk(\lambda)ds \quad (2.27)$$




Figura 2.13: Extinción de un haz incidente por una capa infinitesimal de la atmósfera (Wallace)

donde ρ es la densidad del aire, r es la masa del gas por unidad de masa de aire, $k(\lambda)$ es el coeficiente de scattering (o absorción) de masa, con unidades de m^2kg^{-1} . Se puede integrar a la ecuación 2.27 desde el tope de la atmósfera ($z = \infty$) hasta cualquier nivel (z) para determinar qué fracción del haz incidente ha sido atenuado por absorción y/o scattering. Si se considera $ds = \sec(\theta)dz$ se obtiene:

$$\ln(I(\lambda, \infty)) - \ln(I(\lambda), z) = \sec(\theta) \int_z^\infty k(\lambda)\rho rdz \quad (2.28)$$

Tomando el antilogaritmo de los dos lados se obtiene:

$$I(\lambda, z) = I(\lambda, \infty)e^{-\tau(\lambda, z)\sec(\theta)} = I(\lambda, \infty)T(\lambda, z) \quad (2.29)$$

donde $\tau(\lambda) = \int_z^\infty k(\lambda)\rho rdz$ y $T(\lambda, z) = e^{-\tau(\lambda, z)\sec(\theta)}$ es la transmisividad de la capa. Este conjunto de relaciones y definiciones se conocen colectivamente como ley de Beer y dicen que la intensidad monocromática $I(\lambda)$ disminuye de manera monótona con la longitud de la trayectoria a medida que la radiación pasa por la capa. A la cantidad adimensional $\tau(\lambda)$ se le suele referir

como profundidad óptica normal y es una medida del decrecimiento acumulativo que un haz de radiación directamente dirigido para abajo (ángulo de zenith $\theta = 0$) experimentaría al pasar por la capa. Si se considera una ausencia de scattering, la absorción monocromática se aproxima exponencialmente a la unidad de acuerdo a la profundidad óptica:

$$\alpha(\lambda, z) = 1 - T(\lambda, z) = 1 - e^{-\tau(\lambda, z) \sec(\theta)} \quad (2.30)$$

Se puede definir profundidades ópticas para el scattering y para la extinción (absorción + scattering) de la radiación de manera equivalente.

La conservación de la energía requiere que para la radiación incidente en una capa se respete:

$$\alpha^f(\lambda) + R^f(\lambda) + T^f(\lambda) = 1 \quad (2.31)$$

donde $\alpha^f(\lambda)$, $R^f(\lambda)$ y $T^f(\lambda)$ son los flujos de absorción, reflectividad y transmisividad. La radiación incidente puede ser dispersa más de una vez en el pasaje por una capa. Las sucesivas dispersiones aumentan la diversidad de caminos de rayos. Si hubiera una ausencia total de la absorción, lo que comenzó siendo un haz de radiación paralelo puede terminar en una radiación isotrópica, lo que complejiza enormemente el modelo previamente expuesto. Aquí se mencionan tres parámetros usados para caracterizar las propiedades ópticas de los aerosoles, gotas y cristales de hielo:

- Coeficiente volumétrico de extinción $N\sigma K(\lambda)$, medida de la importancia general de las partículas para eliminar radiación del haz incidente.
- Albedo de dispersión única, medida de la importancia relativa del scattering y la absorción, definido como:

$$\omega_0(\lambda) = \frac{K(\lambda, \text{scattering})}{K(\lambda, \text{absorción})} \quad (2.32)$$

- Parámetro de asimetría:

$$g(\lambda) = \frac{1}{2} \int_{-1}^1 P(\cos\theta') \cos\theta' d\cos\theta' \quad (2.33)$$

donde $P(\cos\theta')$ es la distribución angular normalizada de la radiación dispersada (función de fase de scattering) y θ' es el ángulo entre la radiación incidente y la radiación dispersa. El factor de asimetría va desde -1 a 1, es 0 para radiación isotrópica y tiene valores positivos cuando predomina el scattering hacia delante (scattering frontal).

A pesar de que el scattering de la radiación por parte de gotas esféricas de nube es predominantemente frontal, la dispersión múltiple de haces de luz paralelos resultan en una distribución de la intensidad mucho más isotrópica que en el caso de cielo libre de nubes. Es por esto que

las nubes son las principales contribuyentes al albedo planetario (porcentaje de la radiación reflejado de una superficie). En muchos casos y dependiendo de la longitud de onda empleada, el análisis de imágenes satelitales con presencia de nubes se convierte en un problema superficial de nubes, debido a la imposibilidad de tener acceso a la información volúmetrica de las mismas.

2.2.5. Introducción a los Satélites Artificiales

Se define una plataforma como:

“Un objeto artificial que orbita la Tierra a una altitud mínima de 20 km en la estratósfera y máxima de 36.000 km en el espacio”

Existen plataformas de diversos tipos, entre ellas los **satélites artificiales**, plataformas que fueron lanzadas y ubicadas en su órbita por cohetes. Los satélites artificiales llevan consigo instrumentos de medición de diversos tipos, dependiendo del objetivo para el cual fueron creados. Existen múltiples clasificaciones de los satélites y sus instrumentos de medición:

- Órbita baja (LEO), órbita media (MEO) y órbita alta.
- Órbita geoestacionaria (GEO), satélite de órbita alta, permanece fijo respecto a un punto del planeta, y órbita polar (PEO), satélite de órbita baja, gira periódicamente alrededor de la Tierra pasando por los polos y visitando cada punto con una frecuencia fija en el caso de ser heliosincrónicos.
- Con sensores activos (miden señales producidas artificialmente luego de que interactuaran con algún objetivo, un ejemplo son los radares) o con sensores pasivos (miden señales como la radiación del sol reflejada por objetos en la Tierra, un ejemplo son los radiómetros).

Los satélites actuales llevan a bordo múltiples instrumentos que hacen observaciones completas y a gran escala de diferentes elementos meteorológicos, tanto en las capas más bajas como en las más altas de la atmósfera [34].

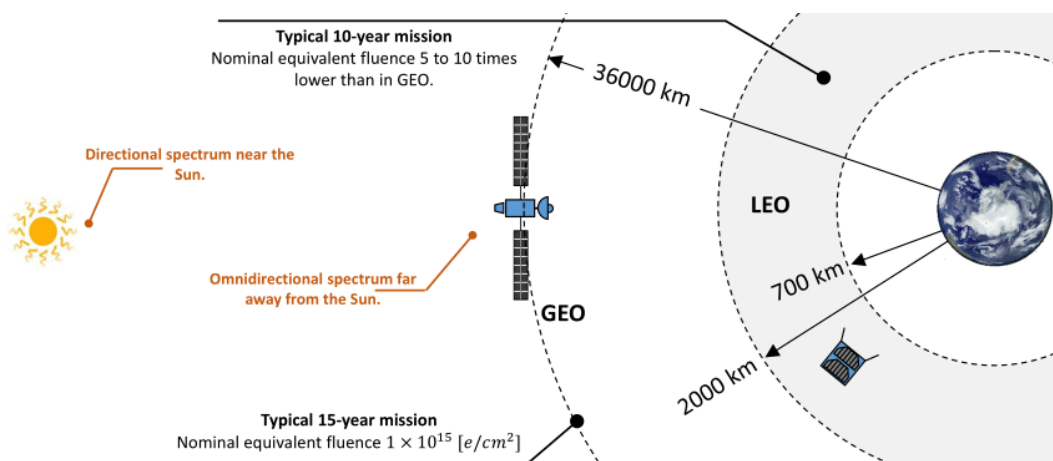


Figura 2.14: Ilustración de los satélites GEO y LEO [6]

En la figura 2.14 se observan un satélite LEO y uno GEO. Ambos tienen sus ventajas y desventajas. Los satélites LEO tienen acceso a bandas visibles e IR pero son especialmente útiles para información de MW, tanto activa como pasiva, tienen mejor resolución espacial en ese rango, tienen una cobertura espacial más limitada y, con la excepción de los polos, ven cada porción solo dos veces por día. Por otra parte, los satélites GEO ofrecen un monitoreo continuo, no tienen una gran resolución, son buenos con información en IR y Vis, en especial pasiva, y no son capaces de observar las regiones polares pero son muy buenos para las latitudes medias y los trópicos.

2.2.6. Señales Geofísicas

Los valores medidos por un sensor espacial son usualmente una combinación de múltiples señales geofísicas [35] [7]. La mayoría de estas señales se esquematizan en la figura 2.15, entre las cuales identificamos:

- Radiancia de la atmósfera seca, sensible a la presión, temperatura y humedad.
- Radiancia que se origina de capas de nubes suspendidas, se transmite a través de la parte superior de la atmósfera y es generalmente sensible a parámetros ya mencionados 2.2.4 y a características particulares de la nube, como el tamaño de las partículas, densidad, distribución vertical, etc.
- Radiancia originada de la precipitación, se transmite a través de la atmósfera y sensible a la presión, temperatura, humedad, entre otros.
- Radiancia originada de la superficie, transmitida a través de la atmósfera seca, depende del tipo de los suelos (océano, tierra, criósfera), cada una con distintas emisividades y reflectividades.
- Radiancia originada de la superficie, parcialmente absorbida y/o dispersa a través de la atmósfera por nubes suspendidas o precipitantes.
- Radiancia emanada por la atmósfera, posteriormente reflejada en el suelo y transmitida de nuevo a través de la atmósfera hasta llegar al sensor.

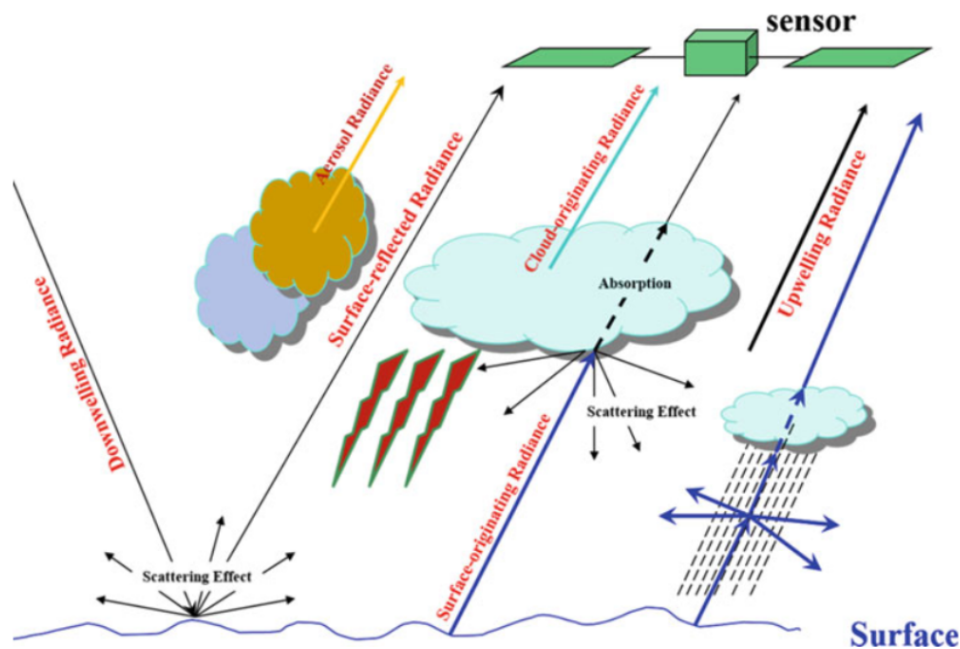


Figura 2.15: Ilustración de las señales que llegan a los sensores espaciales [7]

Se comprueba que la información recibida en los sensores satelitales es extremadamente difícil de analizar. Tanto las propiedades ópticas de los componentes de las nubes y partículas en el aire como características espectrales de la superficie terrestre afectan las mediciones de un sensor. A su vez, estas últimas también dependen de la geometría de la superficie, de la temperatura y de factores como la cantidad y tipo de vegetación presente.

Las maneras de operar con la teledetección satelital dependen enormemente de las necesidades y propósitos del usuario. La idea fundamental consiste en extraer la información necesaria de la señal que llega al sensor para procesarla, mientras se contabilizan todos los parámetros que puedan impactar en la misma. A la hora de asimilar los datos, lo ideal es recurrir a modelos complejos de transferencia radiativa, donde se toman en cuenta la mayor cantidad de procesos individuales posibles (vegetación, nubes, cenizas de un volcán, etc). Por supuesto, este es un problema mucho más complejo que la explicación que aquí se expone.

2.2.7. Radiómetros y Formación de Imágenes

Se le otorga el término radiómetro a los instrumentos diseñados para medir el flujo de radiación electromagnética. Algunos radiómetros miden el flujo contenido en un haz de luz con un ángulo sólido y una sección conocida, mientras que otros miden el flujo recibido de múltiples direcciones. A su vez, los radiómetros pueden ser diseñados para recibir información de un gran rango de longitudes de onda o para una banda espectral en particular. De esta manera, construyen imágenes, convirtiendo la radiación que los objetos transmiten en datos digitales (Mccluney, Encyclopedia of Physical Science and Technology).

En general, un instrumento electro-óptico consiste de 4 componentes principales [36]:

1. Un telescopio o un aparato de imagen similar.
2. Un detector en el plano focal del telescopio, el cual puede incluir filtros u otros elementos para la selección de longitud de onda.
3. Un montaje de calibración que permita que la respuesta del detector de fotones sea interpretada en unidades radiométricas (es el único que puede no estar).
4. Un conversor analógico-digital que permita que las observaciones del instrumento sean codificadas y transmitidas a la Tierra.

Para formar una imagen, el sensor remoto debe hacer un muestreo de una gran cantidad de intensidades usando una combinación entre el desplazamiento del satélite en una dirección (*along-track*) y algún aparato mecánico que proyecte los elementos del detector en numerosas ubicaciones. Hay tres cantidades importantes para caracterizar una imagen: el campo de visión (FOV, por sus siglas en inglés), el campo de visión instantáneo (IFOV) y el campo de visión instantáneo de campo (GIFOV). El FOV se define como la extensión angular del swath cruzado del sensor; el IFOV es la extensión angular de un detector individual, proyectado a través del telescopio; el GIFOV es la proyección del detector en la escena (sea la superficie de la tierra o una capa atmosférica en particular). De esta manera, la resolución espacial es una función del campo de observación del sensor y de su distancia de la superficie de la Tierra. Los 3 valores se pueden observar en la figura 2.16.




Figura 2.16: Parámetros espaciales de la teledetección satelital [8]

La imagen construida dependerá principalmente de la franja del espectro electromagnética elegida, entre otros factores como la sensibilidad, la respuesta del sensor, el tiempo de escaneo, etc. Los radiómetros suelen lograr la selección de “bandas” mediante filtros en el plano focal, en

frente del detector. En el caso que sea necesario medir radiación infrarroja y visible al mismo tiempo con distintos tipos de detectores, se posiciona un divisor de haces de luz en frente del telescopio para enviar las porciones del espectro a sus respectivos sistemas de filtros/detectores. Hay dos categorías de detectores: termales y de fotones. Los primeros funcionan en base a cambios de propiedades eléctricas (como la resistencia) a partir de la radiación incidente, con la particularidad de tener tiempos de respuesta más largos. En los detectores de fotones, la radiación incidente libera electrones, lo cual produce una corriente proporcional al número de electrones incidentes que puede ser medida con dispositivos fotoconductores, fotovoltaicos o fotoemisivos.

La radiancia medida por el sensor en cada ubicación es almacenada con un número digital (Digital Numbers, DN), por cuestiones de optimización en la transferencia de información o almacenamiento. Los números digitales son utilizados para asignar una escala de grises a los píxeles en la imagen satelital final. Es decir, se construye una correspondencia entre las mediciones de las radiancias con una escala de enteros, por ejemplo entre 0 y 255, entonces cada píxel de la imagen tiene asignado un entero de este rango, donde 0 representa el negro y 255 el blanco. En particular, ABI tiene una resolución radiométrica de 12 bits.

2.2.8. Visualización de las imágenes satelitales

Muchas veces es necesario utilizar imágenes de más de un canal para visualizar mejor algún fenómeno en particular. Para ello, se utilizan múltiples imágenes tomadas por el mismo instrumento, de la misma zona y al mismo tiempo. El método más usual es el de la composición RGB, donde se apilan 3 imágenes de distintas bandas y se forma una imagen “a color” con los colores primarios: Rojo (R), Verde (G) y Azul (Blue). De esta manera, cada píxel de la imagen tiene un color definido por un triplete de valores enteros entre 0 y 255. Este sistema de colores se denomina RGB y se lo puede pensar como el sistema cartesiano de la figura 2.17.

Al probar diferentes combinaciones de bandas o incluso cambiando el orden de las mismas, los colores de la imagen final cambian. Las distintas pruebas permiten detectar objetos y características que con una sola banda no se podrían visualizar. La elección de las distintas combinaciones es un trabajo experimental por parte del investigador, de todas formas, existen fórmulas de composiciones ya provistas por los servicios satelitales como “Color Real”, que se forma con las 3 bandas del espectro visible, “Microfísica de Día” o “Fase de Nubes Diurna”, entre otros.




Figura 2.17: Sistema de coordenadas cartesiano para RGB [9]

2.2.9. Satélite GOES-16

El Geostationary Operational Environmental Satellite - 16 (GOES-16) [37] es un satélite meteorológico geostacionario y es parte de la constelación GOES de la NOAA. Fue lanzado en noviembre de 2016 y desde mediados de diciembre de 2017 ocupa la posición de 75.2°W. Está principalmente destinado al estudio del continente americano y su área de cobertura es aproximadamente de 68° latitud Norte a 68° latitud Sur y 148° longitud Oeste a 2° longitud Oeste. Su altitud es de unos 35786 km.




Figura 2.18: Satélite GOES-16 con sus instrumentos a bordo, incluyendo el ABI

En la figura 2.18 se observan los 6 instrumentos a bordo, siendo el Advanced Baseline Imager (ABI) el principal. Consiste de un radiómetro que puede capturar imágenes en 16 canales distintos: 2 en el visible, 4 en el cercano al infrarrojo (NIR) y 10 en el infrarrojo (IR). En el cuadro 2.2 se muestran los canales, el rango de longitud de ondas que detectan, la longitud de onda central, su resolución espacial y los principales usos de cada uno.

Cuadro 2.2: Resumen de longitudes de onda, resolución y usos de las bandas de ABI

Banda	Rango [μm]	Centro [μm]	Resolución [km]	Uso Principal
1	0,45 – 0,49	0.47	1	Aerosol de día sobre tierra, mapeo costero y de agua
2	0,59 – 0,69	0.64	0.5	Niebla de día, insolación, vientos
3	0,846 – 0,885	0.865	1	Vegetación de día, rastros de fuego, aerosol sobre agua, vientos
4	1,371 – 1,386	1.378	2	Nubes de cirrus de día
5	1,58 – 1,64	1.61	1	Fase de tope de nube diurna, tamaño de partículas, nieve
6	2,225 – 2,2275	2.25	2	Propiedades de tierra y nubes de día, tamaño de partículas, nieve
7	3,80 – 4,00	3.90	2	Superficies y nubes, niebla de noche, fuego, vientos
8	5,77 – 6,6	6.19	2	Vapor de Agua a nivel alto, vientos, lluvia
9	6,75 – 7,15	6.95	2	Vapor de Agua a nivel medio, vientos, lluvia
10	7,24 – 7,44	7.34	2	Vapor de Agua a nivel bajo, vientos, lluvia, SO ₂
11	8,3 – 8,7	8.5	2	Total de agua para estabilidad, fase de nube, polvo, SO ₂ , lluvia
12	9,42 – 9,8	9.61	2	Ozono, turbulencia y vientos
13	10,1 – 10,6	10.35	2	Superficie y nubes
14	10,8 – 11,6	11.2	2	Temperatura de superficie de mar, nubes, lluvia
15	11,8 – 12,8	12.3	2	Total de agua, cenizas, Temperatura de superficie de mar
16	13,0 – 13,6	13.3	2	Temperatura del aire, alturas de nubes

Las escenas que toma ABI pueden corresponder a tres áreas distintas: CONUS (América

del Norte), Mesoescala (imágenes 1000x1000km para análisis de mediana escala) o el *Full Disk* (Disco Completo). En este trabajo es de interés el último formato ya que es el único que cubre nuestra región de interés.

En cuanto a la resolución temporal, ABI tiene 3 modos de escaneo para la escena de Disco Completo: el Modo 3, con observaciones cada 15 minutos, el Modo 6 cada 10 minutos y el Modo 4 cada 5 minutos. En este trabajo se emplea exclusivamente el Modo 6.

Los productos generados vienen en distintos niveles de procesamiento. Los productos nivel 0 (L0) consisten de los paquetes de datos completos de ciencia, de estado, ingeniería, telemetría y comunicaciones de cada uno de los 6 instrumentos. Para cada instrumento existe además un archivo L0 con la información de órbita y apuntamiento generados por la plataforma. El nivel de procesamiento L1A tiene aplicadas ciertas correcciones, en especial radiométricas, por lo que la calibración está garantizada. Tanto los productos L0 como los L1A solo son accesibles por los empleados de GOES-16.

Los productos de más bajo nivel que se entregan son los L1B [38], donde se aplican correcciones geométricas en base a los datos de navegación del satélite, además de corregir todos los desalineamientos relativos entre las bandas. Estos datos son interpolados para llevarlos a la grilla fija de ABI, una proyección basada en la perspectiva de vista de la ubicación idealizada del satélite (ver figura 2.19). En el nivel de procesamiento L2 [39], los productos contienen datos procesados provenientes de combinaciones de la información de radiancia original, tales como máscaras de nubes (Clear Sky Mask), detección de aerosoles (Aerosol Detection) o datos de lluvia (Rainfall Rate/QPE), la cual se emplea en este trabajo.




Figura 2.19: Grilla de productos L1B o L2, donde n es la cantidad total de píxeles que contiene la imagen. Para el caso de un producto *Full Disk*, la resolución espacial de 2 km tiene $n=5424$; si es de 1 km, $n=10828$ y si es de 0.5 km, $n=21696$.

2.3. Clasificación de Imágenes

Se entiende por clasificación al proceso de agrupar en distintas clases o categorías a elementos de una población que comparten determinadas características en común.

La clasificación de imágenes se define como el proceso de tomar decisiones cuantitativas a partir de datos extraídos de imágenes, agrupando píxeles o regiones de la imagen en clases que representen distintos objetos físicos o tipos. Es importante aclarar que este proceso de clasificación está basado en un análisis estadístico y probabilístico de los datos. Puede ser llevado a cabo tanto por el científico como por un algoritmo, en cuyo caso nos adentramos en el ámbito del aprendizaje automático

2.3.1. Algunos Principios básicos del aprendizaje automático

Para comenzar, voy a aclarar qué se considera como aprendizaje automático y cuáles son las vías para hacerlo. Se puede definir lo primero de manera muy general como el procedimiento de que la computadora mejore en una tarea en particular con la práctica. Para ello, se puede elegir distintas tácticas[40]:

- Aprendizaje Supervisado: se provee un conjunto de entrenamiento con etiquetas ya conocidas y a partir de ese conjunto de datos el algoritmo generaliza para responder correctamente a cualquier input que se pueda presentar.
- Aprendizaje No Supervisado: Las respuestas correctas no son provistas, el algoritmo intenta identificar similitudes entre las muestras existentes y categorizarlas en conjunto. Aquí entran los procesos de *clustering*.
- Aprendizaje Reforzado: Un punto medio entre lo supervisado y lo no supervisado. El algoritmo sólo es corregido, no se le indica la solución correcta, debe aprender por su cuenta las diferentes posibilidades.
- Aprendizaje Evolutivo: se ve a la evolución como un proceso de aprendizaje en el que los organismos biológicos se adaptan para sobrevivir. Se adapta este modelo en la computadora mediante el concepto de *fitness*.

El tipo de aprendizaje más común es el supervisado y es el que vamos a emplear en este trabajo. En aprendizaje automático, se entiende por problema de clasificación a la idea de agrupar elementos de una población en N clases o categorías de acuerdo a características en común. Los puntos más importantes a considerar en una clasificación es su carácter discreto y que se asume que el conjunto de clases elegido compone el total de las predicciones posibles. Esto no es completamente cierto para algunos casos: ciertos elementos pueden pertenecer parcialmente a dos categorías y se puede alimentar a nuestro clasificador con un elemento inesperado [40].

El proceso de clasificación (y de muchos problemas de aprendizaje automático) se puede dividir en 6 etapas:

1. Recolección y Preparación de los datos: la primera parte y posiblemente la más importante, los resultados finales de una clasificación dependen de que el tratamiento de los datos sea el adecuado. Incluye la descarga de la información (input data y etiquetas), su distribución en directorios, la identificación de fallas y/o errores y la selección de acuerdo al objetivo final de nuestra clasificación. También hay que tener en cuenta la cantidad de datos elegidos para eficientizar los recursos a disposición.
2. Selección de Variables: existen infinitas características para tener en cuenta, de acuerdo a qué y cómo se quiere clasificar se eligen las más adecuadas. Esta etapa requiere un conocimiento previo del problema que se aborda.
3. Elección del Algoritmo: de acuerdo a los datos a disposición y del problema a resolver, ¿Cuál algoritmo es el mejor?
4. Selección de Modelo e hiperparámetros: los algoritmos actuales contienen muchos hiperparámetros. La selección de los mismos se puede realizar por herencia de otros trabajos relevantes o por la propia experimentación para identificar valores apropiados.
5. Entrenamiento y Validación: Se provee un subconjunto de la información del dataset y mediante el acierto y el error se entrena al algoritmo en la predicción de los datos de etiqueta. Se habla de validación en conjunto con el entrenamiento porque de manera paralela se prueba al algoritmo con información no provista en el entrenamiento (no queremos que sobreajuste o aprenda de memoria los ejemplos de entrenamiento).
6. Evaluación: Antes de que un algoritmo sea puesto a disposición del público, es necesaria la elección de métricas para evaluar la performance del mismo. Se eligen datos distintos a los usados durante el entrenamiento y los resultados son interpretados por especialistas del tema.

En este trabajo se trata el caso de segmentación de imágenes satelitales, particularmente la clasificación de los píxeles según intensidades de lluvia. El objetivo final es crear Mapas Temáticos como el de la figura 2.20, una descripción espacial de características u objetos en un área determinada de la Tierra [31]. Para la construcción algorítmica de estos mapas de lluvia nos enfocaremos en el estudio de las Redes Neuronales.

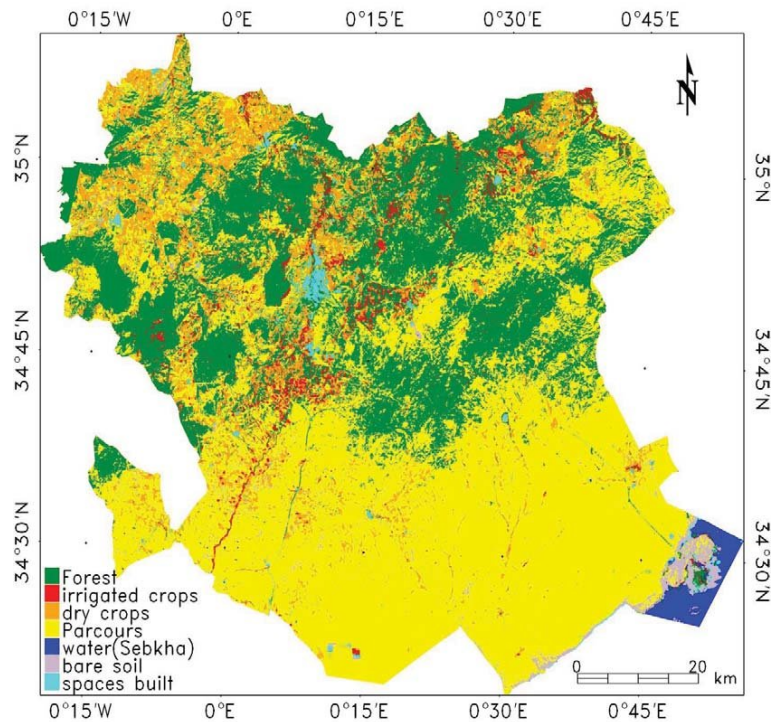


Figura 2.20: Ejemplo de Mapa Temático: Clasificación de suelos con Redes Neuronales en Argelia [10]

2.3.2. Nociones de Redes Neuronales

El estudio de las redes neuronales se ve parcialmente inspirado por la observación de sistemas de aprendizaje biológicos construidos por una red compleja de neuronas interconectadas. De manera simplificada, las redes neuronales están constituidas por un conjunto de unidades simples interconectadas, donde cada unidad recibe señales de entrada, las procesa mediante operaciones y en función de esas señales emite una señal de salida [15].

Para visualizarlo, se puede hacer uso del modelo matemático de McCulloch y Pitts en la cual consideraron a una neurona como:

1. Un conjunto de señales de entrada pesadas w_i que corresponden a la sinapsis
2. Una sumatoria que incorpora todas las señales de entrada (similar a la membrana de la célula que recolecta la carga eléctrica)
3. Una función de activación ϕ , que refleja el comportamiento de la señal de salida




Figura 2.21: Modelo Computacional de la Neurona de McCulloch-Pitts [11]

La neurona de McCulloch y Pitts (ver figura 2.21) es una versión simple para una clasificación binaria en la que la función de activación solo comprueba que la sumatoria pase un determinado umbral para activar la neurona.

Antes de adentrarnos en el tipo de red empleada en este trabajo, haré una breve explicación de 4 conceptos básicos: las redes Feed-Forward, funciones de costo, backpropagation y funciones de activación.

2.3.2.1. Redes Feed-Forward

Se puede clasificar a las arquitecturas de redes neuronales en dos grupos:

1. Redes Prealimentadas (Feed-Forward), donde la información fluye con una dirección definida, de principio a fin
2. Redes recurrentes, donde la información puede fluir en bucles y retroalimentarse

En este trabajo vamos a interesarnos por el primer tipo. En algunas redes Feed-Forward, se puede caracterizar a sus neuronas como neuronas de entrada, neuronas ocultas y neuronas de salida. Estas neuronas están organizadas en capas, generalmente conectadas de manera consecutiva. Las neuronas ocultas, a pesar de tener un nombre misterioso, no son más que neuronas sin conexión con el mundo exterior. Para su diseño e implementación, los investigadores han llevado a cabo múltiples pruebas para obtener el funcionamiento querido de sus redes [41].

Uno de los modelos más simples es el del perceptrón multicapa ³ y cuyo modelado matemático es el siguiente:

$$y_i^j = g\left(\sum_{k=0}^{n_{i-1}} w_{i,k}^j y_{i-1}^k\right) \quad (2.34)$$

donde y_i^j es la salida de la neurona j en la capa i , n_{i-1} es el número de neuronas en la capa $i-1$, $w_{i,k}^j$ es el peso de la conexión entre la neurona y_i^j en la capa i y la neurona y_{i-1}^k en la capa $i-1$ y $g(x)$ es la función de activación no lineal.

³Link con detalles de la historia: <https://news.cornell.edu/stories/2019/09/professors-perceptron-paved-way-ai-60-years-too-soon>.




Figura 2.22: Arquitectura del Perceptrón Multicapa [12]

2.3.2.2. Funciones de costo y Backpropagation

Hasta ahora se ha descrito la estructura general de algunas redes neuronales, pero aún queda entender cómo aprende la red neuronal. Para ello, es necesario proveerle a la red una medida que nos indique cuán mal está prediciendo para poder minimizar ese error respecto al espacio de parámetros de la red (como los pesos ya mencionados) y obtener mejores resultados. De esta manera se introduce a la función de costo J que compara las predicciones de la red con las etiquetas correctas para poder determinar que tan lejos está el modelo de encontrar la relación deseada entre las variables de entrada y las etiquetas de salida.

El algoritmo por el cual se entrena una red neuronal Feed-Forward para minimizar la función de costo es llamado Backpropagation (propagación de errores hacia atrás). Consiste en calcular el gradiente de la función de costo respecto a los parámetros de la red de manera iterativa desde la última capa hasta la primera, haciendo uso de los gradientes de la capa anterior.

El concepto fundamental en este proceso de Backpropagation es el de Descenso por Gradiente. Dentro de los algoritmos de este tipo vamos a mencionar los siguientes:

- Descenso por el gradiente clásico

Es un método de optimización iterativo de primer orden. Un paso en la actualización es:

$$\vec{\Theta}_{t+1} = \vec{\Theta}_t - \eta \nabla_{\Theta} J(\vec{\Theta}_t) \quad (2.35)$$

donde $J(\vec{\Theta})$ es el costo promediado sobre todo el conjunto de entrenamiento, $\vec{\Theta}$ es el conjunto de parámetros, η es la tasa de aprendizaje y ∇_{Θ} es el gradiente con respecto a los parámetros. Estos algoritmos constan de hiperparámetros (como la tasa de aprendizaje η) que controlan el comportamiento del mismo y no son ajustados durante el entrenamiento

si no que son otorgados a la entrada del modelo. En la figura 2.23 se muestra un ejemplo de la importancia de ajustar correctamente estos valores.

- Descenso por el gradiente estocástico en minibatch

En este algoritmo, en vez de usar todo el dataset para cada iteración se divide aleatoriamente el conjunto de entrenamiento en muestras (batches) con b elementos y se obtiene la función de costo promediando sobre esa cantidad de elementos. La ecuación que describe este algoritmo es:

$$\vec{\Theta}_{t+1} = \vec{\Theta}_t - \eta \nabla_{\Theta} J(\vec{\Theta}_t, x^{i:i+b}, y^{i:i+b}) \quad (2.36)$$

Este método es computacionalmente más eficiente que el clásico, puede ser más ruidoso y la elección apropiada del valor b depende del problema a resolver.

- Estimación de momento adaptativo: Adam [42]

Este método está basado en el descenso de gradiente estocástico y está diseñado para acelerar el proceso de optimización. Esto lo realiza al guardar un promedio exponencial en decadencia de los de los gradientes pasados y de sus cuadrados, similar al momento que conocemos en la física. De esa manera, Adam se comporta como una pelota pesada con fricción en búsqueda de una superficie plana en la superficie de error. La ecuación de actualización es:

$$\vec{\Theta}_{t+1} = \vec{\Theta}_t - \frac{\eta}{(\sqrt{\hat{v}_t} + \epsilon)} \hat{m}_t \quad (2.37)$$

donde \hat{m}_t y \hat{v}_t son estimados modificados del primer momento (la media) y del segundo momento (la varianza no centrada) de los gradientes.




Figura 2.23: Efecto de la tasa de aprendizaje en el entrenamiento del modelo

2.3.2.3. Funciones de Activación

Como ya se mencionó, cada neurona posee una función que se aplica a la sumatoria pesada de las variables de la entrada. Estas son necesarias por dos motivos: restringen los resultados de cada neurona a un rango de valores de acuerdo a nuestros requisitos y tienen la habilidad de romper la linealidad y aprender patrones más complejos de los datos.

En la figura 2.24 se muestran algunos ejemplos de funciones de activación. ReLU es una de las más empleadas para las conexiones entre capas escondidas de las redes neuronales. La función sigmoide también es usada en la capa de salida para predecir una probabilidad y es la más usada para clasificaciones binarias. En el caso de clasificaciones con múltiples categorías, se suele usar la función de activación Softmax en la capa de salida.

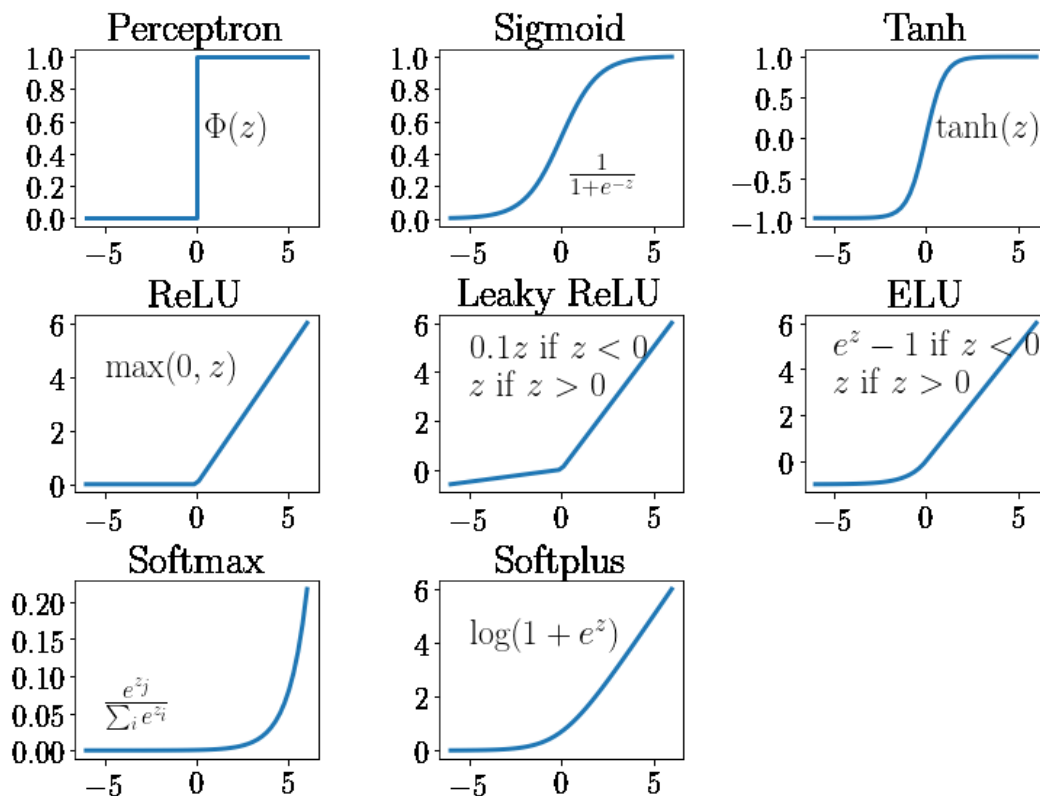


Figura 2.24: Ejemplos de funciones de activación [13]

2.3.3. Deep Learning

Hasta ahora, al explicar el concepto de las redes hemos recurrido a ejemplos simples, llegando hasta el perceptrón multicapa. Variaciones de estos son muy útiles para muchos problemas. Sin embargo, numerosos resultados teóricos sugieren que las redes profundas son intrínsecamente más poderosas [43]. Estas redes son capaces de emplear las capas intermedias para construir múltiples capas de abstracción. Por ejemplo, para el reconocimiento de patrones visuales, las neuronas en la primera capa pueden identificar los bordes mientras que las capas subsiguientes se encargan de identificar formas más complejas [41].

Sin embargo, el aumento de capas en la red neuronal implica una mayor cantidad de pesos para ajustar a la hora de entrenar, lo que puede requerir mayor poder de computación, más tiempo y principalmente mayor cantidad de datos para el entrenamiento. A su vez, en muchos casos, a la hora de entrenar una red profunda se produce un estancamiento del aprendizaje en las capas iniciales o finales⁴. La red profunda que se emplea en este trabajo pertenece a un tipo de red conocida como Red Neuronal Convolutiva, la cual será analizada en más profundidad en la siguiente subsección.

2.3.4. Redes Neuronales Convolutivas

Para el trabajo con imágenes es sumamente importante tener consideraciones de la estructura espacial de las mismas. Las redes neuronales convolutivas tienen una arquitectura que intenta tomar ventaja de dicha estructura, suelen ser muy útiles para la clasificación de imágenes e intentan ser más eficientes para el entrenamiento [41]. En esta sección se explican los conceptos claves para entenderlas.

2.3.4.1. Convoluciones y Campos Receptivos Localizados

Las capas convolutivas son el elemento fundamental para una red convolutiva. Contienen un conjunto de kernels (filtros), que son los parámetros a aprender a lo largo del entrenamiento. Como estos filtros suelen ser más pequeños que la matriz original, el kernel se desliza a lo largo y a lo ancho de la imagen para crear un Mapa de Características mediante el producto escalar entre el filtro y las submatrices del mismo tamaño (Campos Receptivos Localizados)⁵. Este proceso se denomina convolución y está descrito en 2D por la siguiente ecuación:

$$S[i, j] = (K * I)[i, j] = \sum_{m=-l}^l \sum_{n=-l}^l I[i - m, j - n] K[m, n] \quad (2.38)$$

- $K[m, n]$ es el elemento del kernel K en la fila m y columna n . K tiene $(2l + 1) \times (2l + 1)$ elementos.
- I es la imagen bidimensional, con $d \times d$ elementos.
- S es la salida de la convolución, también bidimensional, con $(d - 2l) \times (d - 2l)$ elementos.

⁴Para más detalles relacionados a la inestabilidad del descenso de gradiente, leer Capítulo 5, *Neural Networks and Deep Learning*, Nielsen, 2013 [41].

⁵Para aprender más del tema, leer *Visualizing and Understanding Convolutional Networks*, Zeiler y Fergus, 2013.[44]




Figura 2.25: Diagrama de la convolución en imágenes

Un ejemplo del proceso se puede observar en el ejemplo de la figura 2.25. Cada capa suele tener más de un kernel del mismo tamaño, por lo que se obtiene como salida de cada neurona un volumen de mapas de características concatenados. A su vez, cada elemento de los mapas sólo estuvo conectado a una pequeña región de la imagen y todos las neuronas de un mismo mapa comparten los mismos pesos. Esto permite extraer las mismas características de distintas secciones de los datos con un mismo kernel. Se suele generar una larga secuencia de convoluciones en este tipo de redes: las capas iniciales se encargan de capturar las características de bajo nivel (como líneas) y las capas más profundas de extraer las de alto nivel (formas y objetos específicos).

2.3.4.2. Pooling

Además de la convolución, otro tipo de capa que se encuentra en las redes convolucionales son las de Pooling. Estas consisten en filtros que reemplazan el resultado en una ubicación específica del mapa de características por una sumatoria estadística de los píxeles cercanos. Por ende, el primer efecto que tiene es reducir las dimensiones del mapeo, lo cual reduce el número de parámetros a aprender.

Hay muchos ejemplos de pooling, siendo los mas importantes “max pooling”, que asigna el elemento de la región cubierta por el filtro, y “average pooling”, que calcula el promedio de los elementos. En la figura 2.26 se visualiza cómo actúan estos dos filtros. En todos los casos, el pooling sirve para hacer a la representación invariante a pequeñas traslaciones de la imagen original o para lidiar con imágenes de entrada de distintos tamaños.




Figura 2.26: Operaciones de Max Pooling y Average Pooling

2.3.5. Arquitectura de la Red Neuronal Cloud-Net

Para nuestro problema, es necesario que la salida final de la red convolucional sea de la misma dimensión que la imagen inicial. Los procesos previamente descritos reducen el tamaño de la imagen, por lo que en nuestro caso es necesario que haya dos brazos: uno de contracción y otro de expansión. El primero es el encargado de la extracción y producción de características de “bajo nivel” (líneas, puntos, bordes), mientras que el segundo utiliza esas características y recupera atributos espaciales y globales de la imagen. La arquitectura de la red que empleamos se muestra en la figura 2.27 y está basada en la red U-Net [45]. Algunas de las operaciones empleadas son las ya descritas: convoluciones y max pooling. La gran diferencia surge en las convoluciones transpuestas, que son las que permiten recuperar las dimensiones originales de la imagen.




Figura 2.27: Esquema de la red Cloud-Net

Cloud-Net fue originalmente modificada respecto a U-Net para la detección de nubes en imágenes 192x192, con lo cual el resultado final en su paper [2] consiste de un mapa de probabilidades de que cada píxel sea efectivamente un píxel de nube. Para nuestro trabajo, al interesarnos la clasificación por intensidades de lluvia y no solamente la presencia de lluvia, se obtiene como output N mapas de probabilidades, donde N es el número de categorías propuestas. Para entender a este tipo de redes es necesario explicar algunos conceptos más.

2.3.5.1. Convoluciones Transpuestas y Unpooling

Las operaciones de convolución y pooling mencionadas en la subsección 2.3.4 tienen sus inversas correspondientes. Estas son necesarias para generar una salida con las dimensiones de

la entrada original.




Figura 2.28: Ejemplo de aplicación de la Convolución Transpuesta

Se puede ver cómo actúa la convolución transpuesta en la figura 2.28. Consiste en un sobremuestreo de la matriz mediante un kernel. En el caso del unpooling, existen muchas opciones, siendo algunas de las más usadas vecinos más cercanos (copia un valor de pixel a todos los elementos de la subregión de salida) y max unpooling (recuerda la posición del máximo elegido en el pooling correspondiente a la contracción y rellena los otros espacios con valores nulos). En la figura 2.29 se muestra el caso de max unpooling.

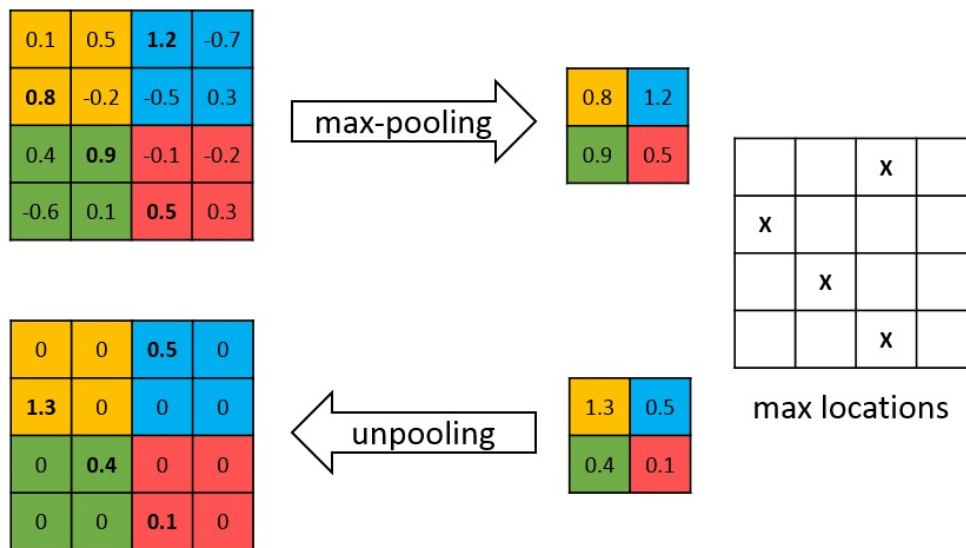


Figura 2.29: Ejemplo de Max Unpooling

2.3.5.2. AutoEncoder y comparación con U-Net

Los AutoEncoders son un tipo de red neuronal feed-forward entrenadas de una manera no supervisada para aprender la representación comprimida del dato de entrada crudo. Consiste de tres partes: el encoder, el espacio latente y el decoder. El encoder comprime la imagen a dimensiones más bajas y el decoder reconstruye la imagen desde esta representación. El espacio latente es una codificación de la imagen en un espacio de dimensión inferior que logra almacenar la información más importante de la misma. Se puede observar la arquitectura del AutoEncoder en la figura 2.30




Figura 2.30: Arquitectura del AutoEncoder [14]

A pesar de preservar la dimensionalidad de la imagen, la comparación lineal del AutoEncoder no permite la transmisión de todas las características. U-Net y Cloud-Net, además de ser métodos supervisados, superan esta dificultad al agregar conexiones de salto que permiten que las representaciones de características pasen “por encima” del espacio latente, tal como se muestra en la figura 2.27.

2.3.5.3. Convoluciones 1x1

Si se observa detalladamente la figura 2.27, se puede notar el uso de una capa peculiar: la convolución 1x1. Esta fue introducida por primera vez en el año 2014 por Min Lin [46]. El número de filtros utilizadas en capas convolucionales suele ser proporcional a la profundidad de la red, lo cual resulta en un aumento del número de mapas de características. Esto resulta en una gran cantidad de parámetros a calcular y en una necesidad computacional cada vez más alta. Los filtros de pooling tienen la capacidad de disminuir los tamaños de estos mapas pero son incapaces de reducir el número de filtros en el modelo, la profundidad ni el número de canales y es por esto que surgen las convoluciones 1x1. Estas tienen un solo peso para cada canal en el input y resultan en un solo valor de salida, lo cual las posibilita a actuar como una neurona sola con un input desde la misma posición en cada uno de los mapas de características. Esta neurona luego se puede aplicar sistemáticamente, resultando en un mapa de características del mismo ancho y largo que el input.




Figura 2.31: Visualización de la convolución 1x1 para un input de dimensiones $64 \times 64 \times 192$ y un output de dimensiones $64 \times 64 \times 1$

Los filtros 1×1 son relativamente simples ya que no es necesario involucrar píxeles vecinos en el input, de hecho, no debería ser considerada una operación de convolución, si no más bien como una proyección del input. Es por esto que estas capas son buenas para resumir la información de los mapas de características, permitiendo la reducción de canales en el proceso. Este no es exactamente el uso que se le da en la red neuronal Cloud-Net. En ella 2.27, se usa el filtro 1×1 de manera paralela a la convolución 3×3 y luego se concatena el mapa de características resultante con todos los canales producidos en el otro camino. Es decir, se genera un canal extra con información mixta de los canales de input.

2.3.6. Otros Métodos Posibles: XGBoost

En los últimos años, las redes convolucionales han adquirido una gran relevancia en el procesamiento de imágenes por los buenos resultados obtenidos en diferentes áreas. Sin embargo, dentro del aprendizaje supervisado, existen muchos algoritmos de distintas características capaces de afrontar el problema de interés de nuestro trabajo. Por sólo mencionar algunos: los árboles de decisión, los métodos de ensamble, modelo lineal generalizado, vecinos más cercanos y análisis de discriminante.

En este trabajo emplearemos para la comparación con la red a un método muy particular: el XGBoost [3]. Entender a este algoritmo requiere de un conocimiento profundo de conceptos de árboles de decisión y gradient boosting, entre otros. Con la aceleración de la “Big Data”, comenzó el proceso de crear nuevos algoritmos para producir predicciones precisas y óptimas. Los árboles de decisión tenían la complicación de aprender demasiado del conjunto de entrenamiento provisto y fallar a la hora de generalizar con nueva información. De esta necesidad surge la idea de combinar múltiples árboles mediante métodos de boosting (XGBoost) o bagging

(Random Forest)[47].

2.3.6.1. Árboles de Decisión

XGBoost está compuesto de muchos “aprendices” base, entre los cuales se encuentran los árboles de decisión. Es uno de los métodos más usados y más prácticos de inferencia inductiva. Permite aproximar información discreta (categorías) al dividir las columnas de input en preguntas. Los árboles de decisión parten de raíces y terminan en hojas a través de múltiples nodos. Los nodos especifican una prueba de un atributo en una instancia determinada y están conectados por ramas. Un árbol de decisión puede crear miles de ramas hasta mapear lo mejor posible un conjunto de entrenamiento y, tal como fue mencionado, los árboles tienden a tener fallar al ser presentados con nueva información [15] [47].

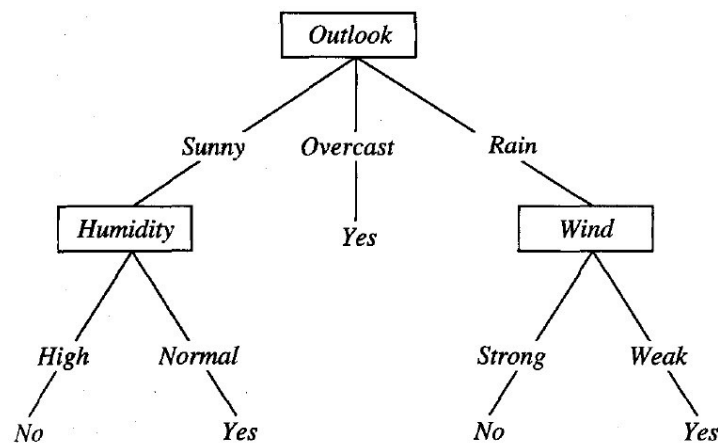


Figura 2.32: Ejemplo simple de Árbol de Decisión para salir de la casa (Decisión Binaria) [15]

2.3.6.2. Gradient Boosting

Para mejorar las predicciones de los árboles de decisión, se propusieron muchos algoritmos capaces de combinar distintos modelos. Por ejemplo, Random Forest emplea un método conocido como Bootstrap Bagging, en el cual se dividen los datos en múltiples árboles de decisión y se incorporan todos los resultados. El problema de este tipo de métodos es que no hay un aprendizaje respecto a los árboles previamente ejecutados, en cambio Boosting construye los nuevos árboles de decisión respecto a los errores de los árboles previos.

Gradient Boosting lleva este esquema aún más lejos: basa enteramente sus ajustes en las predicciones incorrectas, sin importarle los resultados acertados. Esto lo hace al computar los residuales (la diferencia entre el resultado observado y el predicho) de cada una de las predicciones de los árboles y los suma para evaluar al modelo.

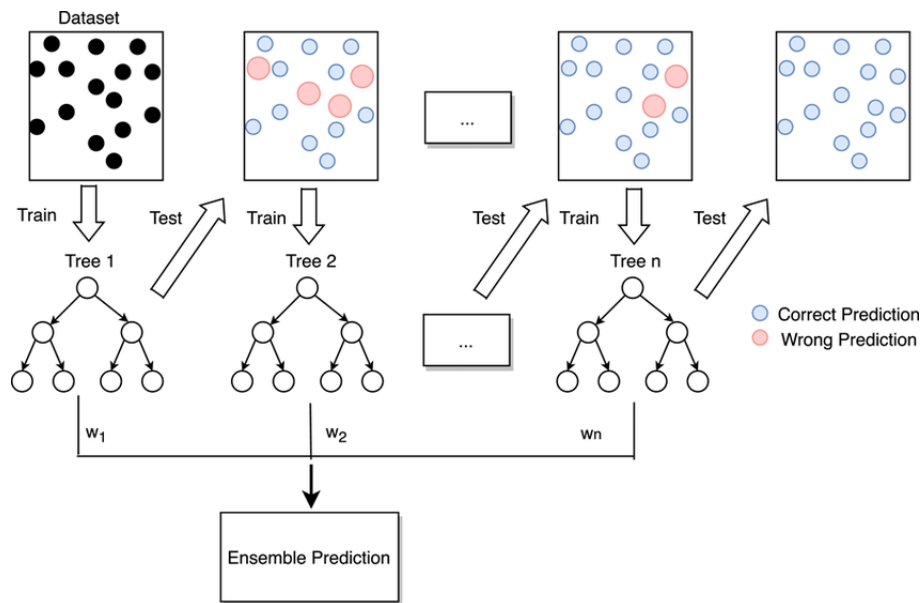


Figura 2.33: Diagrama de Flujo de Gradient Boosting [16]

2.3.6.3. Ventajas de XGBoost

Los autores de XGBoost y sus usuarios mencionan numerosos argumentos por los que este algoritmo obtiene mejores resultados que la competencia y con mayor rapidez. Aquí voy a enumerar dos [47]:

- **Computación Paralela:** Boosting no es ideal para este tipo de proceso porque los resultados de cada árbol dependen del árbol anterior. Sin embargo, XGBoost es capaz de hacerlo al ordenar y comprimir los datos en bloques. Estos bloques son posteriormente distribuidos a muchas máquinas o a una memoria externa.
- **Regularización:** Consiste en el proceso de agregar información con el fin de reducir la variancia y prevenir el overfitting o el underfitting. A grandes rasgos, se puede definir a XGBoost como una versión regularizada de gradient boosting. XGBoost emplea 3 parámetros regularizados que penalizan la complejidad: básicamente regulan los criterios de pérdida para la generación de una nueva rama y suavizan los pesos finales de cada una de las hojas.

Capítulo 3

Metodología

3.1. Base de datos

En esta sección se especifican las bandas empleadas en el trabajo, los detalles para la obtención del producto de precipitaciones QPE, la elección geográfica y temporal de las imágenes que se estudian y algunos detalles del procesamiento previo de la información.

3.1.1. Bandas empleadas

En la subsección 2.2.9 se introdujeron los canales o bandas disponibles del satélite GOES-16¹. Para la obtención del producto QPE se emplean exclusivamente 5 de esas bandas (todas en el IR)²:

1. Banda 8 (6.2 μm): banda de vapor de agua alto, es usualmente empleada para el seguimiento de vientos troposféricos altos, estimación de humedad en niveles altos e identificación de regiones con potencial para turbulencia.
2. Banda 10 (7.3 μm): banda de vapor de agua bajo, puede llegar a la región de la tropósfera media en condiciones sin nube, se la suele emplear para seguir vientos troposféricos bajos, estimar humedad en niveles bajos e identificar potenciales regiones de turbulencia.
3. Banda 11 (8.5 μm): banda de fase de nube, es un canal “ventana” porque tiene poca absorción atmosférica de energía cuando no hay nubes. Además, las gotas de agua tienen una distinta emisividad a comparación de otras longitudes de onda.
4. Banda 14 (11.2 μm): banda de onda larga, también es conocida como un canal “ventana” pero las gotas de agua tienen absorción de energía para esta longitud de onda.
5. Banda 15 (12.3 μm): banda de “ventana sucia”, es absorbida y reemitida por el vapor de agua, particularmente en la tropósfera baja, generalmente tiene temperaturas de brillo más bajas para píxeles sin presencia de nubes.

¹Link de información de las bandas ABI [48].

²Las bandas y el producto QPE se pueden descargar de la página oficial de NOAA. [49]

3.1.2. El producto QPE

El producto QPE consiste de un algoritmo que identifica y deriva tasas de lluvia (de 0 a 100 mm/h) a partir de las bandas de radiancia previamente mencionadas, con una resolución de 2 km. Se puede observar el diagrama de flujo del algoritmo en la figura 3.1, el cual se resume en 4 partes importantes:

1. Definición de 8 combinaciones lineales de las temperaturas de brillo (en la descripción del producto QPE se usa el término predictores).
2. Identificación de píxeles con lluvia mediante un análisis de discriminante contra los datos de precipitación proveniente de satélites con información de MW (clasificación binaria de píxeles). Se emplea la siguiente fórmula para esta etapa:

$$y_c = b_{c,0} + b_{c,1}x_{c,1} + b_{c,2}x_{c,2} + \epsilon_c \quad (3.1)$$

donde y_c son los datos de lluvia estimados a partir de información en MW, las $x_{c,i}$ son pares de predictores derivados de información de ABI, los $b_{c,i}$ son coeficientes de calibración y ϵ_c es el error residual. El procedimiento primero se lleva a cabo con un predictor y una vez elegido el mejor se busca a su mejor acompañante. Los datos de lluvia son continuos por lo que también es necesaria la elección de un umbral para la discretización de la información (0=No Lluvia y 1=Lluvia). Para la selección de los predictores se usa el Heidke Skill Score:

$$HSS = \frac{2(c_1c_4 - c_2 + c_3)}{(c_1 + c_2)(c_2 + c_4) + (c_3 + c_4)(c_1 + c_3)} \quad (3.2)$$

donde c_1 es el número correcto de No Lluvia, c_2 es el número de falsas alarmas, c_3 es el número de detecciones falladas y c_4 es el número de estimaciones de lluvia correctas. El valor perfecto de HSS corresponde a 1.

3. A los 8 predictores ya definidos se les agregan 8 transformaciones no lineales de los mismos (total de 16 predictores). Se enfoca en una regresión por pasos de los píxeles de contra la información de MW a partir de la ecuación 3.1. Se elige el mejor predictor con el coeficiente de correlación de Pearson:

$$Correlacion = \frac{cov(x, y)}{\sigma_x \sigma_y} \quad (3.3)$$

donde $cov(x, y)$ es la covarianza de los datos obtenidos con el predictor y la de MW y σ_x , σ_y son las desviaciones estándar correspondientes. Luego se busca al mejor acompañante al repetir el procedimiento con los 15 predictores restantes.

- Una vez elegidos el mejor par de predictores para cada paso (identificación de píxeles de lluvia y regresión), se procede exclusivamente con información en el IR con los coeficientes previamente calculados hasta obtener nuevas actualizaciones de los satélites con información en MW. El esquema general es el mismo: primero se determina si llueve en el píxel y luego el valor particular de lluvia.

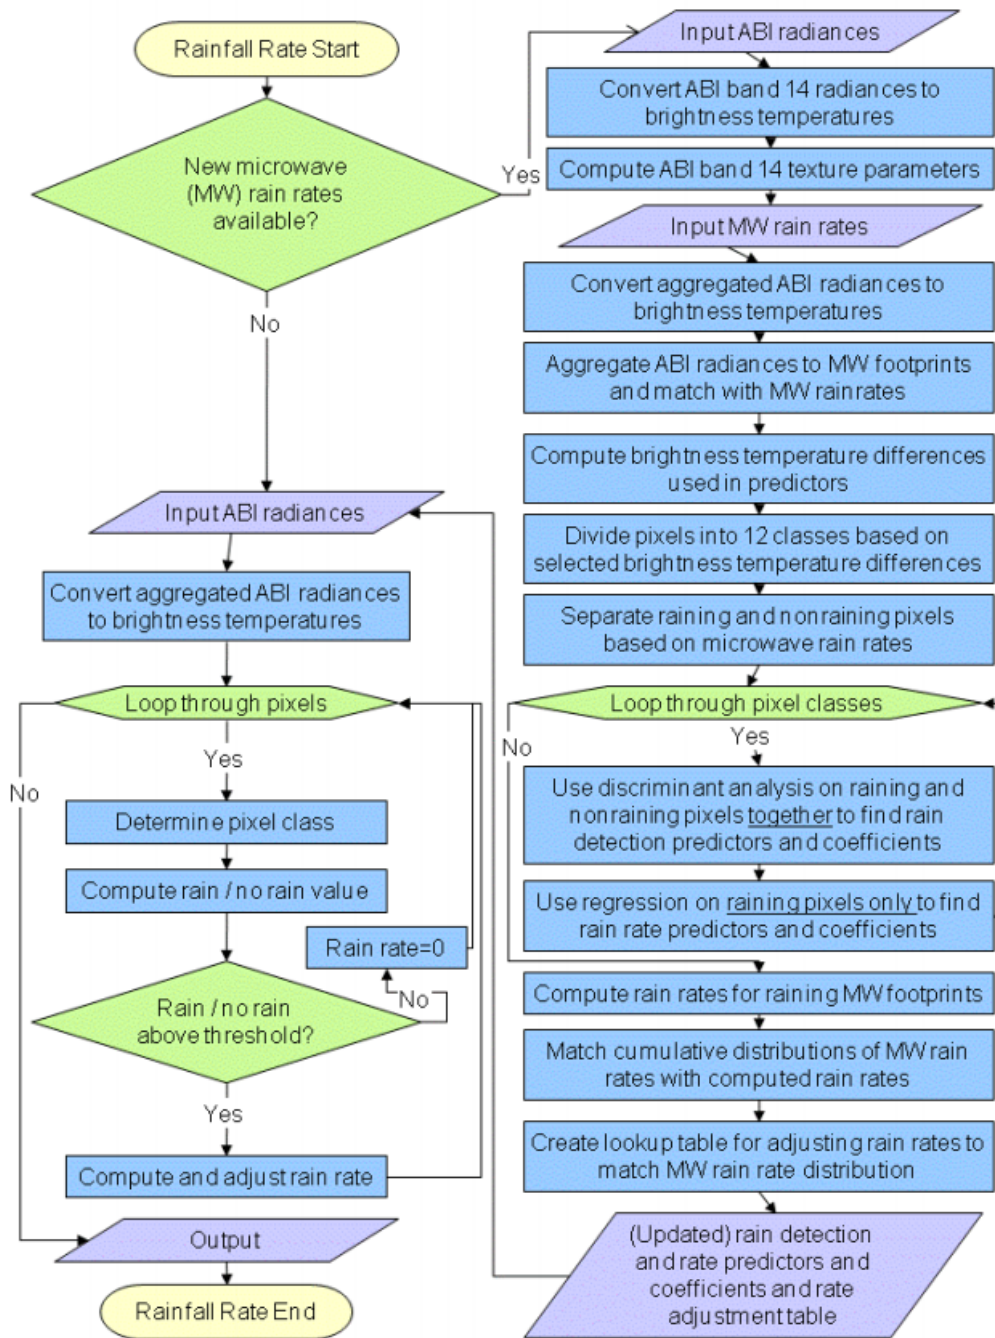


Figura 3.1: Diagrama de flujo del algoritmo QPE

Ya se ha mencionado en las subsecciones de 2.2 que los datos de MW tienen la ventaja sobre el IR porque son sensibles al total de la porción de agua o hielo en la nube y no están restringidas a las propiedades de tope de nube. Sin embargo, los sensores de MW están limitados a órbitas

bajas, por lo que la información no está disponible en una base continua y los resultados corresponden a resoluciones espaciales mucho mayores a las de GOES-16. En particular, el producto QPE se calibra con el producto Nesdis Blended Microwave Rainfall Rate, que tiene una resolución espacial de 16 km. El algoritmo QPE busca aprovechar la combinación de la información más rica en términos volumétricos de los sensores de MW y las ventajas espaciales y temporales del satélite geoestacionario GOES-16.

De todas formas, tal como se aclaró en el resumen de etapas, el algoritmo es capaz de computar valores de precipitación sin la presencia de información de MW. La calibración con los otros satélites se lleva a cabo según la disponibilidad de información y sirve para elegir el mejor par de predictores tanto para la detección de píxeles de lluvia como para la determinación de la tasa de lluvia. A su vez, el proceso descrito en la figura 3.1 y en los items anteriores se lleva a cabo en paralelo para 12 clases distintas de píxeles. Estas clases están definidas por la ubicación en el planeta y por el tipo de nube:

Cuadro 3.1: Clases de píxeles provistas por L0

Latitud	Tipo de Nube	Condición
60°-30°S	Agua	$T_{10} < T_{14}$ y $T_{11} - T_{14} < -0,3$
30°S-EQ	Hielo	$T_{10} < T_{14}$ y $T_{11} - T_{14} \geq -0,3$
EQ-30°N	Convectiva	$T_{10} \geq T_{14}$
30°-60°N		

3.1.3. Elección geográfica y temporal del objeto de estudio

Para muchos problemas vinculados a la geofísica y a la física de la atmósfera, se sabe que la identificación de regiones es muy útil para la caracterización de las condiciones atmosféricas [30]. Esta subdivisión del planeta para el desarrollo de estudios científicos se puede definir mediante el reconocimiento de gradientes profundos y recurrentes de factores climáticos en una misma ubicación [50] o, de manera más arbitraria, por el interés económico, social y/o político en regiones particulares. Paralelamente, la existencia y variabilidad de las estaciones del año son elementos de estudio importantísimos en el aprendizaje del cambio climático [51].

El surgimiento de técnicas de aprendizaje automático como las redes neuronales permiten plantearnos preguntas interesantes: ¿Es necesaria esta clasificación temporal y espacial previa? ¿Puede ser capaz el algoritmo de identificar estos patrones? La posibilidad de generar un clasificador global de condiciones atmosféricas es sumamente tentador pero trae consigo numerosas complicaciones. Algunas de estas son la excesiva cantidad de imágenes satelitales que serían necesarias para entrenar el modelo, la selección (manual o automatizada) de las imágenes para evitar un claro desbalance de los datos y, en el caso que se quieran usar redes convolucionales, la modificación o inserción de las mismas en otro método para tener en cuenta evoluciones temporales.

Con el objeto de ser más eficiente con los recursos disponibles y con la intención de enfocarnos en una porción del continente Sudamericano, se decidió llevar a cabo el estudio desde los 17°S hasta los 39°S y desde los 49°W y los 73°W, área que contiene los países de Uruguay, Paraguay y partes de Argentina, Bolivia, Brasil y Chile (ver figura 3.2). Para poder usar las imágenes en la red Cloud-Net, también fue necesario dividir esta porción terrestre en 25 subregiones de 192x192 píxeles. Esta subdivisión se explica más detalladamente en la subsección 4.1.2. A su vez, se eligieron los primeros 15 días de Enero de 2021 como dato de entrenamiento y el día 16 de Enero de 2021 para el testeado de los modelos obtenidos.

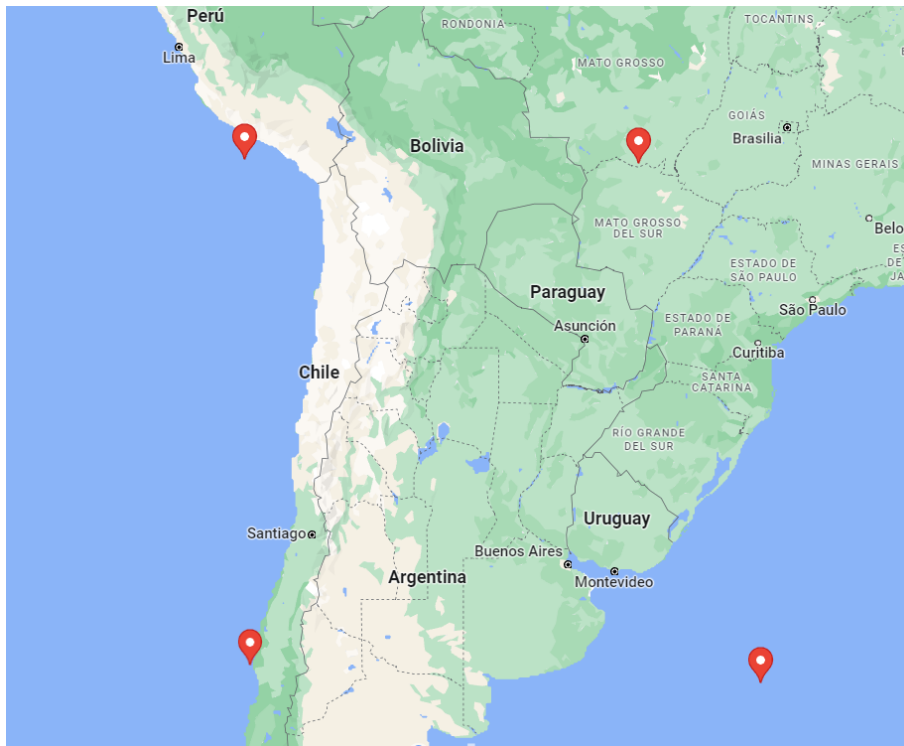


Figura 3.2: Recorte Total elegido para la inserción en la red

3.1.4. Procesamiento previo de los datos

Esta etapa es probablemente la más importante para cualquier trabajo de aprendizaje automático [52]. Como ya he mencionado, el satélite GOES-16 provee una actualización de las imágenes cada 10 minutos en el modo elegido. Esto significa que por banda y por producto es necesario descargar 144 imágenes con una escala de 2 km en el área de estudio total del satélite (ver subsección 2.2.9). Una vez descargados los 16 días elegidos, el total de memoria de almacenamiento requerido es aproximadamente 351 GB. Las subsecciones siguientes buscan aclarar el procedimiento para eficientizar el uso de las imágenes en la red neuronal y la eliminación de imágenes poco confiables. El recorte de las bandas, el entrenamiento y el testeado de la red neuronal junto a la prueba de otros algoritmos se pueden encontrar en la página de Github del

trabajo ³.

3.1.4.1. Posibles errores en el producto QPE

El primer paso en trabajos relacionados a aprendizaje automático es el control y el posible descarte de elementos no deseados. Fue necesario eliminar imágenes con saturación excesiva de lluvia, tales como parches enteros de píxeles con saturación, posiblemente por la falta y/o falla de las temperaturas de brillo empleadas. La saturación de la escala no es algo poco frecuente en este tipo de algoritmos pero es necesario hacer una interpretación de la misma por casos. Se buscaron otras imágenes con presencia de tasas de precipitación mayores a 100 mm/h y, tal como se muestra con los círculos blancos de la figura 3.3, estas se encuentran en los focos de tormenta, lo cual implica que la sobrecarga es representativa del evento analizado y no es necesario el descarte de la imagen.




Figura 3.3: Muestra de sobrecargas en el total de la región de análisis.

En la barra de color de la figura 3.3 introducimos una de las dos divisiones por categorías de intensidades de lluvia que se van a emplear en este trabajo. La elección de estos valores se basa en la bibliografía existente (Proyecto Noah, 2012 [53] & Kirsch et al, 2019 [54]). De

³Link del Github: <https://github.com/fandelsman/Rainfall-Detection-and-Classification-using-Neural-Networks>

todas formas, estas categorizaciones son un tanto arbitrarias y se pueden encontrar muchas clasificaciones e intervalos diferentes si se consultan distintas fuentes:

Cuadro 3.2: Categorías por intensidades de lluvia de píxel

3 Categorías	Condición [mm/h]	6 Categorías	Condición [mm/h]
No lluvia (0)	$Pixel < 0,1$	No lluvia (0)	$Pixel < 0,1$
Lluvia Moderada (1)	$0,1 \leq Pixel < 10$	Lluvia Leve (1)	$0,1 \leq Pixel < 2,5$
Lluvia Fuerte (2)	$10 \leq Pixel$	Lluvia Moderada (2)	$2,5 \leq Pixel < 7,5$
		Lluvia Fuerte (3)	$7,5 \leq Pixel < 15$
		Lluvia Intensa (4)	$15 \leq Pixel < 30$
		Lluvia Torrencial (5)	$30 \leq Pixel$

3.1.4.2. Distribución en directorios

Se crearon carpetas para cada una de las bandas y para los datos de etiqueta. Con el motivo de mantener el orden temporal y la identificación de las subregiones, cada archivo tiene el formato:

- {TipoDeArchivo}File{j}Region{r}.npv

donde el tipo de archivo puede ser el número de la banda o QPE, $j \in [0, 2155]$ es el número de archivo en orden temporal y $r \in [1, 25]$ es el número de la región. El resultado final de este proceso es un total de 53900 imágenes disponibles para el entrenamiento de la red neuronal, cada una con todas las bandas y etiquetas necesarias para el entrenamiento. Con estos índices se puede llevar a cabo el análisis temporal y geográfico del producto QPE de manera más simple, sin tener que recurrir a las imágenes completas. En el caso de los datos de testeo se llevó a cabo el mismo proceso, resultando en 3600 imágenes disponibles.

Esta estructura de datos se logró mediante un código personal de Python, el cual puede ser encontrado en la página de Github del trabajo [55].

3.1.4.3. Selección de Imágenes para el Entrenamiento de la Red

Con los objetivos de reducir el esfuerzo computacional, el almacenamiento necesario y principalmente para evitar el desbalance entre las categorías, se hace una selección previa de las imágenes que se emplean en las clasificaciones binarias y multicategoría.

Para la clasificación binaria se dividió a todas las imágenes por regiones y por porcentajes de píxeles de lluvia vs píxeles de no lluvia: menos de 10 % de lluvia, entre 10 % y 20 %, entre 20 % y 40 % y mayor a 40 %. Debido a la mayor cantidad de imágenes del primer grupo, se usaron aleatoriamente 25 imágenes del grupo 1 por cada región y se usaron el resto de los grupos en su totalidad, lo cual concluyó con un total de 6614 imágenes a disposición para el entrenamiento. En la tabla 3.3 se muestra la contribución de cada grupo:

Cuadro 3.3: Número de contribuciones al entrenamiento de clasificación binaria por grupo

Porcentaje de píxeles de lluvia	Número de Imágenes Usadas
< 10 %	625
Entre 10 % y 20 %	2959
Entre 20 % y 40 %	2292
> 40 %	738

Para la clasificación multicategoría se recurrió a un método más simple. Si se observa la figura 3.3, se puede identificar anillos de intensidades alrededor de las ubicaciones de lluvia más fuertes. Este comportamiento es muy frecuente en las imágenes analizadas y nos permite asegurar que con la presencia de las lluvias más intensas también habrá presencia de las intensidades intermedias. Es por eso que en esta etapa se estableció como condición para el uso de las imágenes en el entrenamiento de la red neuronal a un mínimo de 1000 píxeles de lluvia de las categorías *Intensa* y *Torrencial* de la tabla 3.2. Esta decisión resultó en un total de 1326 imágenes disponibles para el entrenamiento multicategoría.

3.1.5. Información del Servicio Meteorológico Nacional Argentino

Para poder llevar a cabo una verificación visual de los resultados del producto QPE solicitamos acceso a la base de datos de información de tierra de precipitaciones en las 71 estaciones meteorológicas del Servicio Meteorológico Nacional Argentino, desde el año 2000 hasta el 2021 incluido. Estos datos son recolectados diariamente a las 9 am y corresponden a los mm totales que cayeron en el día.

3.2. Funciones de pérdida

En la subsección 2.3.2.2 se introdujeron las funciones de costo o pérdida de las redes neuronales y cuáles son algunos de los métodos para minimizar estos valores. En esta sección se especifican las funciones de pérdida empleadas a lo largo del trabajo, tanto para el caso de clasificación binaria como el multicategoría.

3.2.1. Dice Loss

El coeficiente de dado (Dice Coefficient) es una métrica muy empleada para visualizar la similitud entre dos imágenes. Luego, fue adaptada para poder ser empleada como una función de pérdida:

$$DL(y, \hat{p}) = 1 - \frac{2y\hat{p} + 1}{y + \hat{p} + 1} \quad (3.4)$$

donde y es el valor real de la etiqueta y \hat{p} es la predicción del modelo. En este caso, se agrega un 1 en el numerador y en el denominador para asegurar que la función esté definida en casos límite como $y = \hat{p} = 0$. Dice Loss es una de las funciones de pérdida más empleadas para la segmentación de imágenes y tiene muy buenos resultados a la hora de discernir elementos de un fondo. Sin embargo, puede tener problemas con el desbalance de los datos, es decir, con la predominancia de una categoría en particular. Es decir, ante la presencia de muchas imágenes con una categoría dominante, los ejemplos “fáciles” dominarán el modelo de entrenamiento y se pueden producir resultados no óptimos con ejemplos más complejos [56] [57] [58].

3.2.2. Tversky Loss

El índice de Tversky surge como una generalización del coeficiente de Dado. Agrega un peso a los casos de falsos positivos (FP) y falsos negativos (FN) con la ayuda de un coeficiente β :

$$TL(y, \hat{p}) = 1 - \frac{1 + y\hat{p}}{1 + y\hat{p} + \beta(1 - y)\hat{p} + (1 - \beta)y(1 - \hat{p})} \quad (3.5)$$

Si $\beta = 1/2$, la pérdida de Tversky resulta en la pérdida de dado. A su vez, algunos autores presentan a la pérdida de Tversky con dos hiperparámetros: α como peso para los falsos positivos y β como peso para los falsos negativos. De acuerdo a la necesidad del autor, se puede aumentar uno de los dos respecto al otro para penalizar más uno de los dos casos [56] [59]. En este trabajo se empleó $\beta = 0,7$, siguiendo la bibliografía consultada [57]. Tanto Tversky como Dice Loss sólo fueron empleados en la primera clasificación binaria. En los casos de clasificación con múltiples categorías se usaron las siguientes funciones de pérdida.

3.2.3. Categorical Cross Entropy Loss

La entropía es una medida de la incerteza asociada a una dada distribución $p(y)$ con K estados distintos. A medida que es mayor la entropía, menos seguros estamos del valor que se va a obtener. Se define a la entropía cruzada multiclase como:

$$L(\theta) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^K [y_{ij} \log(p_{ij})] \quad (3.6)$$

donde i indexa cada una de las muestras (en nuestro caso los píxeles), j indexa las clases, y_{ij} es la etiqueta provista previamente y p_{ij} es la probabilidad de que cada píxel corresponda a cada clase. Recordar que en la sección 2.3.4 hemos visto que la salida de una red neuronal convolucional consiste de K mapas de probabilidades de la dimensión de la imagen original.

Cross Entropy puede presentar problemas similares a los de Dice Loss pero para el caso multicategoría. El desbalance de las clases puede provocar la generación de sesgos a la hora de que aprenda la red ya que las clases mayoritarias dominan la función de pérdida y el descenso

por gradiente, provocando que los pesos se actualicen favoreciendo a la predicción de la clase mayoritaria.

3.2.4. Focal Loss

Focal Loss se enfoca en los ejemplos que el modelo ha predicho mal, para asegurarse que los ejemplos complicados mejoren a lo largo del tiempo y no confiarse con los ejemplos fáciles. Esto se logra a partir de una técnica conocida como *Down Weighting*, una técnica que se implementa al agregar un factor modulador a la función de pérdida de entropía cruzada:

$$L(\theta) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^K [y_{ij} \log(p_{ij}) \alpha (1 - p_{ij})^\gamma] \quad (3.7)$$

donde $\gamma \geq 0$ es el parámetro de enfoque y α es un parámetro de balance. Intuitivamente, γ reduce la contribución a la pérdida por parte de los ejemplos fáciles y extiende el rango en el cual un ejemplo recibe una baja pérdida. Por ejemplo, si $\gamma = 2$, un ejemplo clasificado con $p_{ij} = 0,9$ tendría aproximadamente 100 veces menor pérdida comparando con el Cross Entropy usual. En este trabajo se establecen como valores $\alpha = 0,25$ y $\gamma = 2$, los cuales son los usados en la bibliografía consultada [60].

3.3. Resto de Hiperparámetros

3.3.1. Red Cloud-Net

En la subsección 2.3.2.2 se mencionaron a los hiperparámetros, elementos que controlan el entrenamiento de una red neuronal pero no son obtenidos a lo largo del mismo, si no que son previamente establecidos por el investigador. Este trabajo se enfocó principalmente en la comparación de alternativas para uno de ellos: la función de pérdida. Debido a la similitud en el objeto de estudio, a la mayoría del resto de hiperparámetros se les asignó los mismos valores que en el trabajo de Cloud-Net [2]:

- `validation_ratio`: 0.2
- `start_learning_rate`: 1e-4
- `end_learning_rate`: 1e-8
- `decay_factor`: 0.7
- `patience`: 15
- `batch_size`: 8

El hiperparámetro batch size fue modificado de 12 a 8 porque es una convención en redes neuronales la entrega durante el entrenamiento de 2^n muestras a la vez, donde n es un número entero⁴.

3.3.2. XGBoost

El algoritmo XGBoost también tiene hiperparámetros para establecer. La búsqueda de los mismos se hizo mediante un Random Search, el cual consiste en definir una grilla con algunos valores de hiperparámetros y en la selección de combinaciones aleatorias de los mismos para encontrar los mejores resultados. Tanto en el caso de 3 categorías como en el de 6 categorías (no se usa XGBoost en la clasificación binaria), algunos de los hiperparámetros utilizados fueron:

- `subsample`: 0.6 (Random Search)
- `min_child_weight`: 1 (Random Search)
- `max_depth`: 5 (Random Search)
- `gamma`: 1.5 (Random Search)
- `colsample_bytree`: 0.8 (Random Search)
- `base_score`: 0.5
- `booster`: gbtrees
- `colsample_bylevel`: 1
- `learning_rate`: 0.005
- `n_estimators`: 600

3.4. Métricas

La elección de cómo evaluar los resultados de un algoritmo de aprendizaje automático es una parte esencial del proyecto (ver 2.3.1). Dependiendo de los objetivos y características de un trabajo, suele ser necesario priorizar a una métrica respecto a otras. A su vez, se recomienda evaluar la performance de un algoritmo con múltiples métricas, de manera tal de analizar los resultados desde distintas ópticas. Vale aclarar que las métricas elegidas en este trabajo son principalmente útiles para problemas de clasificación.

⁴Para aquel interesado, es un tema de discusión en múltiples foros, como <https://sebastianraschka.com/blog/2022/batch-size-2.html>

3.4.1. Exactitud

Conocido como *Accuracy* en inglés, la exactitud mide cuan bien predice el clasificador. Consiste en el cociente entre el número de predicciones correctas y el número total de predicciones:

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.8)$$

donde TP son los positivos reales, TN son los negativos reales, FP son los falsos positivos y FN son los falsos negativos. Esto está planteado para una clasificación binaria pero se puede extender fácilmente a un análisis por categoría. El principal problema de la exactitud en un problema de clases desbalanceadas como el que se presenta en este trabajo, es que el resultado global puede ser muy bueno pero esconde los resultados de cada categoría. Existen maneras de solucionarlo, como calcular una exactitud promediada por pesos pero en general se emplean otras métricas que nos dan más información.

3.4.2. Matriz de Confusión

Es una tabla de desempeño con combinaciones de valores predichos y etiquetas reales. Lo interesante de la matriz de confusión es que permite una visualización rápida en el caso de clasificación multicategoría de cuáles son las categorías que se confunden entre sí.

		PREDICTED	
		POSITIVE	NEGATIVE
ACTUAL	POSITIVE	TRUE POSITIVES	FALSE NEGATIVES
	NEGATIVE	FALSE POSITIVES	TRUE NEGATIVES

Figura 3.4: Visualización de una Matriz de Confusión binaria

Vamos a emplear la matriz de confusión para explicar otras métricas usuales en el ámbito del aprendizaje automático.

1. Precisión: Explica cuántos de los casos predichos positivos resultan ser positivos. Es muy útil cuando los falsos positivos son más preocupantes que los falsos negativos.

$$Precision = \frac{TP}{TP + FP} \quad (3.9)$$

2. Sensibilidad: También conocido como *recall* en inglés, explica cuántos casos positivos verdaderos fuimos capaces de predecir con nuestro modelo. Es una métrica muy importante cuando los falsos negativos son más preocupantes que los falsos positivos.

$$Sensibilidad = \frac{TP}{TP + FN} \quad (3.10)$$

3. F1-Score: Nos otorga una idea combinada de la precisión y la sensibilidad. Adquiere el máximo valor cuando la precisión equivale a la sensibilidad. Tiene como contra que es difícil su interpretación

$$F1 = 2 \frac{Precision * Sensibilidad}{Precision + Sensibilidad} \quad (3.11)$$

4. Soporte: *Support* en inglés, indica la cantidad de muestras que existen de cada clase en el conjunto de evaluación/testeo.

Es importante aclarar que todas estas métricas son complementarias entre sí y que en casos de múltiples categorías como el que se presenta en este trabajo, es necesario interpretarlas una por una. Los resultados de las métricas para cada prueba se encuentran principalmente en los Reportes de Clasificación del Apéndice 5.1.

3.4.3. Distancia de Hamming

Es una métrica proveniente de la teoría de la información. Fue originalmente pensada para teoría de códigos y depende de la diferencia total entre las letras de una palabra válida del código y otra de la misma longitud. En nuestro caso, se puede pensar que cada píxel de la imagen está compuesto por números enteros y la distancia de Hamming total sería la sumatoria del módulo de la diferencia entre la predicción en cada uno de los píxeles y su etiqueta real. Es decir:

$$Hamming = \sum_i^N \sum_j^N |y_{ij} - \hat{p}_{ij}| \quad (3.12)$$

donde i es el número de fila, j es el número de columna y N es el valor total de filas/columnas (se supone una imagen cuadrada). Además del resultado global, también son importantes los resultados parciales para obtener histogramas de diferencias entre píxeles o visualizaciones espaciales de las diferencias. Esta métrica es muy importante en un problema de clasificación por escalas porque permite interpretar a los errores de acuerdo a por cuánto está fallando la

predicción. A su vez, si se adapta la métrica de Hamming y se le saca el módulo, se puede tener una idea si el modelo está subestimando o sobrestimando la cantidad de lluvia.

3.5. Software y Hardware

El código del programa fue realizado íntegramente en lenguaje Python. Se corrió la red neuronal de dos maneras distintas: la clasificación binaria se llevó a cabo con un GPU en Google Colab y la clasificación de múltiples categorías se llevó a cabo con la computadora personal. Esto se debió a las limitaciones de uso de Google Colab, los tiempos de procesamiento de una red neuronal convolucional de estas características son muy largos y el sistema frenaba el proceso antes de su finalización. En el caso de multicategoría, el número de cálculos que ejecuta el sistema son mayores, por lo que era imposible llegar a un número de epochs adecuado para el entrenamiento. El hardware empleado fue:

- Procesador: Intel Xeon CPU @2.20 GHz y Nvidia Tesla K80 GPU en la primera etapa (provisto por Colab) y Intel(R) Core(TM) i7-10750H CPU @ 2.60GHz en la segunda.
- Memoria RAM: 13 GB en la primera etapa y 8 GB en la segunda.
- Almacenamiento: ~ 70 GB en Colab, al ser compartido puede variar el valor exacto, 1,81 TB en la segunda etapa.

El software empleado fue:

- Python 3.7.15 en la primera etapa y 3.8 en la segunda.
- Librerías NetCDF (descarga de archivos), Tensorflow, Keras (red neuronal), Numpy, Pandas y Seaborn (procesamiento de imágenes y resultados) en ambas etapas.
- Colab en la primera etapa y Spyder en la segunda (entorno de desarrollo).
- Windows 11 en la segunda etapa.

Capítulo 4

Resultados

4.1. Abordaje Inicial del QPE

Esta primera sección trata sólomente al producto QPE y busca encontrar patrones temporales y regionales en el comportamiento de las precipitaciones.

4.1.1. Análisis Temporal de las Precipitaciones

Los primeros resultados consistieron en analizar los horarios de mayor precipitación, tomando en cuenta el conjunto de las 25 regiones. A su vez, tal como se mencionó en la subsección 3.1.4.1, se buscan saltos repentinos en la cantidad de píxeles de lluvia para localizar posibles errores en la adquisición de datos. Estos horarios son inmediatamente excluidos de la posterior inserción en la red neuronal.

Los gráficos obtenidos son tanto binarios (Lluvia vs No Lluvia) como de las 6 categorías de intensidad de lluvia definidas en la tabla 3.2, para cada uno de los primeros 15 días de enero. Se puede identificar horarios de mayor cantidad de lluvia y la predominancia de determinadas intensidades de acuerdo al momento del día. A modo de ejemplo, muestro dos gráficos para el día 1 de enero de 2021. Recordar que el día tiene un total de 144 imágenes, con actualización cada 10 minutos, correspondiendo la imagen 0 a las 0 UTC y la 143 a las 23:50 UTC. Nótese la diferencia en los órdenes del número de píxeles total de No Lluvia (Categoría 0) respecto al resto de intensidades 4.1 y 4.2.




Figura 4.1: Diferencia entre número de píxeles de Lluvia y de No Lluvia, 01/01/2021.




Figura 4.2: Diferencia entre número de píxeles de las intensidades de Lluvia, 01/01/2021.

En casi todos los días, se marca este comportamiento de “valle”, con mayor presencia de lluvia al principio (imagen 0, 21 horas en Argentina) y la presencia de un pico entre las imágenes 100 y 143 (entre las 16 y 21 horas en Argentina). Existen excepciones, como el día 04/04/2021, con la presencia de múltiples picos a lo largo del día, tal como se presenta en la figura 4.3. La mejor comprensión de la distribución de las precipitaciones a lo largo del día es objeto de estudio de algunos investigadores en distintas partes del mundo [61] [62].



Figura 4.3: Total de píxeles de lluvia por imagen, 04/01/2021.

4.1.2. Análisis Geográfico de las Precipitaciones



Figura 4.4: Las 25 regiones de análisis

Luego, se dividió la porción terrestre de análisis en las 25 regiones mencionadas en la subsección 3.1.3, tal como se muestra en la figura 4.4. El mapa está basado en Google Earth, cada uno de los globitos marcan las esquinas de las regiones y todas son cuadradas desde el punto de visto de ABI (proyección geostacionaria). Para cada región se identificaron los días de mayor cantidad de lluvia y cuáles son las intensidades que más contribuyen a cada día según la región analizada. A modo de ejemplo, se muestran los valores obtenidos para 3 regiones en particular. La primera región elegida es la número 6, correspondiente al Océano Pacífico justo al lado del desierto de Atacama, destacada por su baja presencia de lluvia ¹. La segunda región es la número 5, en el Mato Grosso Brasileiro, destacada por la presencia de lluvia de todas las intensidades [63], incluyendo un día con predominancia de lluvias mayores a 30 mm/h (lluvia torrencial en nuestra categorización). La tercera región es la número 18, correspondiente a una porción de las provincias de Córdoba, Santiago del Estero, Santa Fé y Catamarca, que alternan días con escasa lluvia y con mucha precipitación de categorías intermedias.

¹Artículo en la revista EOS: <https://eos.org/research-spotlights/understanding-rare-rain-events-in-the-driest-desert-on-earth>




Figura 4.5: Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 6 (Costa Pacífico de Atacama).




Figura 4.6: Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 5 (Mato Grosso).

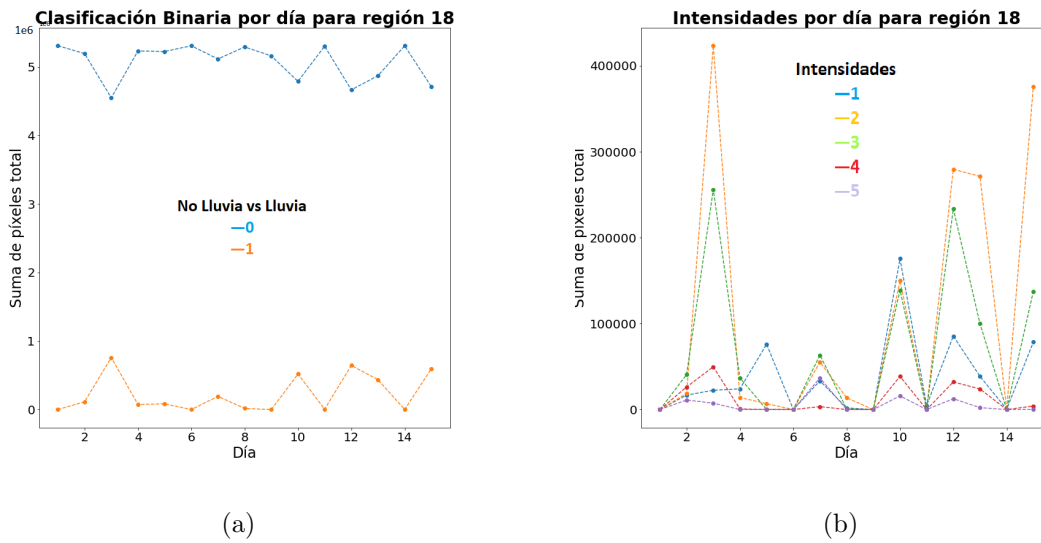


Figura 4.7: Suma de píxeles total por día tanto para clasificación binaria (a) como para las intensidades de lluvia (b) para la región 18 (Centro de Argentina).

4.1.3. Comparaciones contra productos visuales estándar de ABI

En la subsección 2.2.8 se mencionó que se pueden combinar las bandas para formar imágenes RGB y obtener productos visuales. Con el fin de identificar rasgos espaciales vinculados al producto QPE, en las figuras 4.8 se grafica un derivado del producto *Day Microphysics* [18] y el producto QPE correspondiente a ese horario. Se puede notar que las zonas de lluvias (tonos claros en la imagen de la derecha) se corresponden principalmente con las áreas de nubes con partículas de hielo grandes o pequeñas (tonos rojizos y marrones en la imagen izquierda).




Figura 4.8: (a) Producto de Microfísica, con combinaciones de las bandas 3,7 y 13, (b) Producto QPE a las 17:10 UTC del 16/01 en la región 13

Cuadro 4.1: Combinaciones de las bandas empleadas para los productos RGB

Producto	Red	Green	Blue
Day Microphysics	3	7	13
Day Convective Storm	10-8	13-7	2-5

Existe otro producto, denominado *Convective Day Storm*, sin embargo sus resultados no son tan evidentes. Al compararlo con el producto QPE de la figura 4.8, se ve que las zonas de aparente convectividad y desplazamiento vertical de la tormenta (zona blanca dentro de la nube) no corresponden necesariamente a píxeles con lluvia intensa.




Figura 4.9: Producto de Convectividad, con combinaciones de las bandas 2, 5, 7, 8, 10 y 13

Las características y formación de las tormentas convectivas son un tema de estudio importante [64]. Se trata de un problema dinámico en el cual la convección puede aparecer varios minutos antes que la precipitación por lo que es probable que no haya una coincidencia temporal o espacial entre los dos eventos. En las figuras 4.10 se observan las precipitaciones 30 minutos antes y después de las 17:10 en la región 13. Se puede apreciar que una porción de la lluvia intensa se difumina y/o desplaza en ese intervalo temporal.

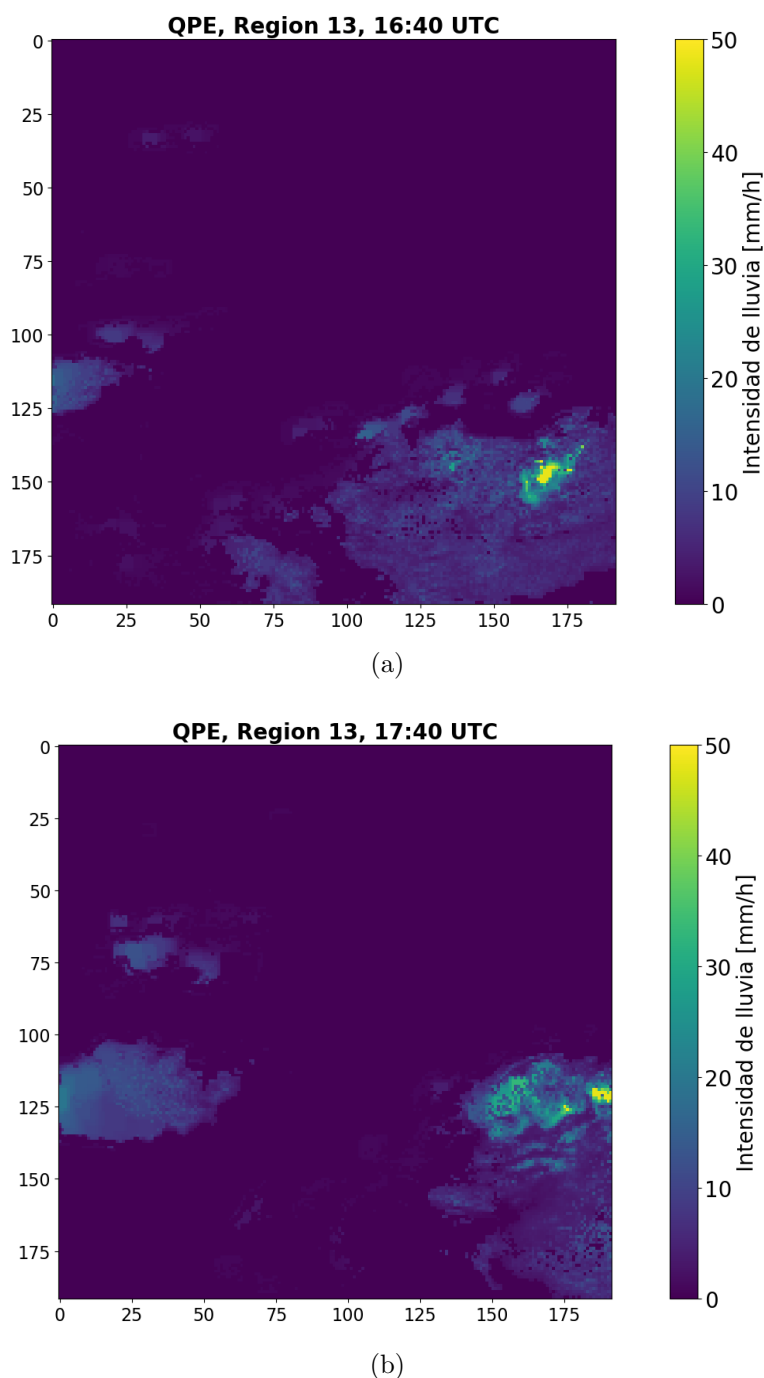


Figura 4.10: (a) Producto QPE a las 16:40 en la región 13, (b) Producto QPE a las 17:40 en la región 13

4.1.4. Comparación del QPE con información de suelo

Tal como se mencionó, en la subsección 3.1.5, se accedió a información de pluviómetros instalados en el territorio argentino. Los valores mostrados corresponden a las precipitaciones desde las 9 am, horario argentino, del día sábado 16/01/2021, hasta las 9 am del domingo 17/01/2021. Además, están superpuestos en la figura 4.11 con la lluvia acumulada diaria del producto QPE. Se produce una clara sobrestimación de las precipitaciones por parte del producto QPE, en particular en los píxeles ubicados entre $x = [590, 660]$ e $y = [400, 450]$, subregión

correspondiente a la provincia de Chaco, más precisamente entre los departamentos de General Guemes y Almirante Brown. Existen antecedentes de lluvias de estos órdenes en la región ² y ese día se registraron lluvias de hasta 105 mm en la localidad de Miraflores que imposibilitaron el tránsito de vehículos ³ (ver apéndice 5.1).

Esta sobrestimación se ve acompañada de una subestimación del producto QPE para incorporar las lluvias leves que recolectan los pluviómetros (puntos blancos). En algunos casos, QPE llega a registrar presencia de lluvia acumulada menor a 7,5 mm, pero no es visible en la imagen por la escala de colores elegida. Finalmente, la precipitación acumulada identificada por QPE tiende a estar muy localizada en algunos sectores y las lluvias mayores a 300 mm/día (zonas rojas) solo se encuentran en una pequeña porción de la imagen sobre la cual no coincide ningún pluviómetro. Así mismo, hay varios pluviómetros que denotan lluvias intensas (puntos rojos) en zonas de bajo QPE (regiones oscuras). Por lo tanto no hay una buena correspondencia entre el estimador satelital y las mediciones in situ.

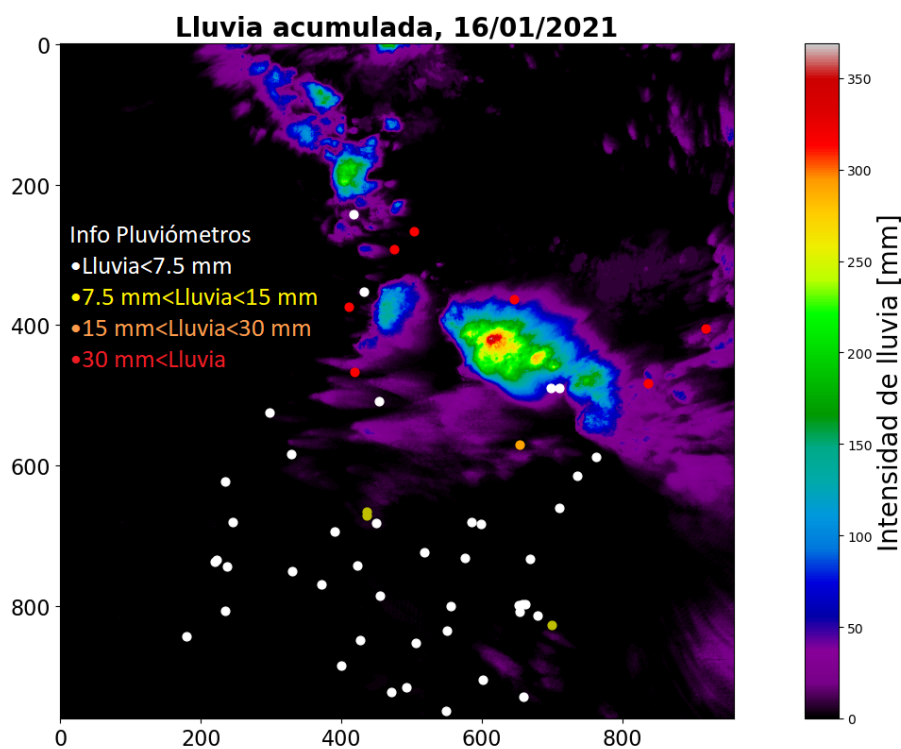


Figura 4.11: Lluvia acumulada desde las 9 ART del día 16/01/2021 hasta las 9 ART del día 17/01/2021. Los puntos corresponden a la información de los pluviómetros y el mapa de colores a la información del QPE

²Noticia de temporal: <https://www.chacodiapordia.com/2022/04/11/temporal-en-castelli-en-una-hora-y-con-fuertes-vientos-hubo-destrozos-en-viviendas-salones-comerciales-voladuras-de-techos/>

³Informe de la policía de Chaco del día 17/01/2021: <https://policia.chaco.gob.ar/index.php/ecmLluvias>

4.2. Uso de Cloud-Net y XGBoost

4.2.1. Clasificación Binaria: Lluvia vs No Lluvia

En una primera instancia se hizo la clasificación binaria de Lluvia vs No Lluvia con Cloud-Net y las funciones de pérdida Dice y Tversky 3.2. El algoritmo XGBoost se emplea solamente en la clasificación multicategoría. Los datos de ingreso de las redes neuronales fueron las radiancias normalizadas de las bandas 10, 11, 14 y 15, sin convertirlas a temperaturas de brillo. Los primeros gráficos presentados (figura 4.12) corresponden al proceso de entrenamiento de la red, se muestra la evolución de las pérdidas respecto a los epochs⁴ para el entrenamiento con Dice Loss y con Tversky Loss. Sorprende el rápido descenso de la pérdida del conjunto de validación y la dificultad para converger a los mismos valores que el conjunto de entrenamiento. Esto se intenta solucionar y se ve con mayor claridad a la hora de tratar el caso de múltiples categorías de lluvia (clasificación No Binaria) y al convertir las radiancias de cada una de las bandas en temperaturas de brillo.





Figura 4.12: (a) Dice Loss vs Epochs para el entrenamiento con Dice Loss, (b) Dice Loss vs Epochs para el entrenamiento con Tversky Loss.


Una vez entrenadas las redes neuronales, se procedió a evaluarlas con el conjunto de datos correspondiente al 16/01/2021. Los gráficos de la figura 4.13 son las matrices de confusión para cada función de pérdida. Nótese que, a pesar del comportamiento no convergente de las curvas de entrenamiento y validación, los resultados superan el 89% de exactitud en ambas categorías. Además, no existen grandes diferencias entre los dos métodos, en el Focal Loss disminuye la exactitud de la categoría “Lluvia” y se produce un traslado de errores a la subestimación del

⁴1 epoch = 1 ciclo completo a través de todo el conjunto de entrenamiento

número de píxeles de lluvia.



(a)



(b)

Figura 4.13: Matriz de confusión con (a) Dice Loss y (b) Tversky Loss.

Para un análisis visual se presenta en las imágenes de la figura 4.14 la máscara real de lluvia contra las predicciones obtenidas con las dos redes neuronales entrenadas. En ambos casos, nótese la capacidad de la red para identificar las posiciones globales de la lluvia, la dificultad para reconocer píxeles de lluvia aislados y la tendencia a “suavizar” las regiones de lluvia. A pesar de obtener peores resultados en la matriz de confusión, Tversky Loss supera a Dice Loss al identificar algunos de los núcleos de lluvia presentes en la etiqueta real.

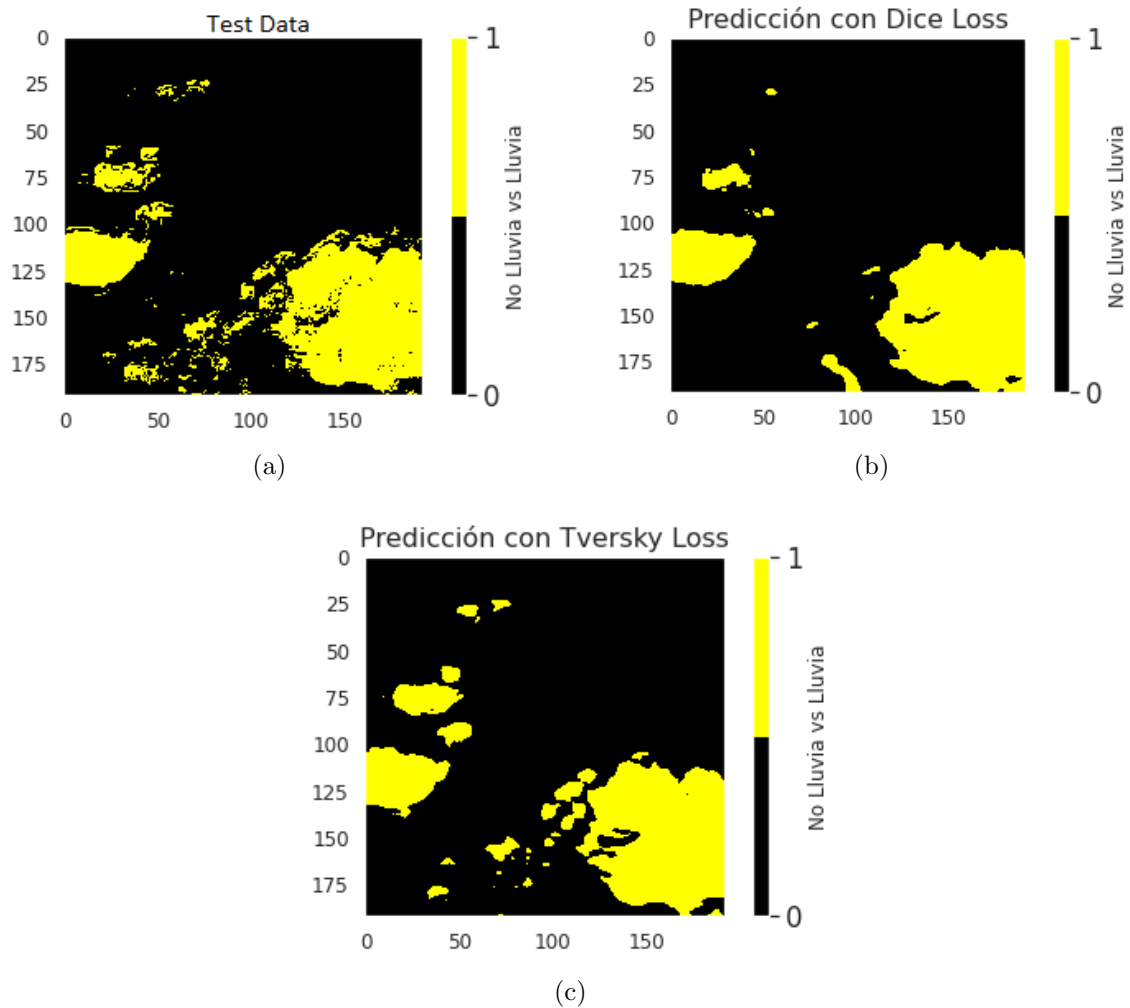


Figura 4.14: Visualización espacial de los resultados de la red Cloud-Net para las 17:10 UTC, 16/01/2021, Región 13 (a) Etiqueta QPE, (b) Predicción con Dice Loss, (c) Predicción con Tversky Loss.

También es útil analizar el Reporte de Clasificación, un resumen de los valores mencionados en la subsección 3.4. Cada una de esas métricas contiene información importante pero el análisis detallado de las mismas no es necesario para la comprensión de este trabajo. A modo de ejemplo se muestra el reporte correspondiente a la red Cloud-Net entrenada con Dice Loss. El resto de los resultados, tanto para la clasificación binaria como para las clasificación de más categorías, se pueden encontrar en el Apéndice 5.1.

Categoría	precision	recall	f1-score	support
0.0	0.993847	0.988400	0.991116	1.724377e+07
1.0	0.844060	0.911203	0.876348	1.188232e+06
accuracy	0.983423	0.983423	0.983423	9.834232e-01
macro avg	0.918954	0.949802	0.933732	1.843200e+07
weighted avg	0.984191	0.983423	0.983718	1.843200e+07

Figura 4.15: Reporte de Clasificación de Cloud-Net con Dice Loss

4.2.2. Clasificación No Binaria

4.2.2.1. 3 Categorías

El siguiente paso fue crear categorías de acuerdo a las intensidades de lluvia (3.2). Se decidió hacer la primera clasificación con 3 clases: No Lluvia, Lluvia < 10 mm/h y Lluvia > 10 mm/h. La decisión viene asociada a la posible identificación de lluvias estratiformes (lluvias estables sin gran intensidad)[54]. Los datos de ingreso a la red ahora son las 5 bandas originales que emplea el producto QPE, es decir, las bandas 8, 10, 11, 14 y 15, convertidas apropiadamente a temperaturas de brillo.

Las funciones de pérdida empleadas fueron Cross Entropy y Focal Loss. En la figuras 4.16 se puede notar la rápida convergencia de la curva de validación en ambos casos, en contraste a los gráficos de entrenamiento 4.12 de la clasificación binaria. Esto se debe probablemente a la mejora del tratamiento previo de las temperaturas de brillo y a la delimitación con valores fijos para la normalización.




Figura 4.16: (a) Cross Entropy vs Epochs para el primer entrenamiento con 3 categorías, (b) Focal Loss vs Epochs para el segundo entrenamiento con 3 categorías.



Figura 4.17: Matriz de confusión para 3 categorías con (a) Cloud-Net y Cross Entropy, (b) Cloud-Net y Focal Loss, (c) XGBoost

El análisis de los resultados resulta similar al de la clasificación binaria. En el segundo conjunto de gráficos 4.17, se muestran las matrices de confusión de la red Cloud-Net y se agregan los resultados obtenidos con XGBoost, con los hiperparámetros mencionados en la subsección 3.3.2. El algoritmo XGBoost tiene peores resultados que las dos variantes de Cloud-Net y tiende a subestimar las intensidades de lluvia. Esto se evidencia más en las figuras 4.18, donde XGBoost es incapaz de identificar los núcleos aislados de clase 1 en la sección inferior de la imagen y algunos núcleos de intensidad 2 en el cúmulo más grande de la derecha. Por otra parte, la red Cloud-Net tiene pequeñas diferencias entre las variantes Cross Entropy y Focal Loss: la primera obtiene mejores resultados para lluvias más intensas pero Focal Loss es

capaz de ser más detallista en las regiones de predominancia de píxeles sin lluvia y mejorar los resultados de la categoría 1.




Figura 4.18: (a) Etiqueta de Test (QPE) y visualización de predicciones para 3 categorías, para las 17:10 UTC, 16/01/2021 en la región 13, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost

4.2.2.2. 6 Categorías

La segunda clasificación se hizo con las 6 categorías de lluvia definidas en la tabla 3.2. Los datos de ingreso fueron los mismos que en la clasificación con 3 categorías: las bandas 8, 10, 11, 14 y 15, convertidas apropiadamente a temperaturas de brillo y las funciones de pérdida empleadas fueron Cross Entropy y Focal Loss. En las figuras 4.19 se puede notar la dificultad para la convergencia de las curvas de entrenamiento y de validación en Cross Entropy y la rápida convergencia de las curvas de validación con las de entrenamiento en el caso de Focal Loss. Es decir, el tratamiento previo y la normalización de las temperaturas de brillo no es

la única explicación para la prevención del overfitting, hay factores más complejos en juego, probablemente relacionados a la función de pérdida elegida.

Para aquel interesado en más detalles de las temperaturas de brillo y sus rangos de valores, en la subsección 5.1 del apéndice se encuentran algunas distribuciones de las temperaturas de brillo para cada una de las 6 categorías previamente definidas.


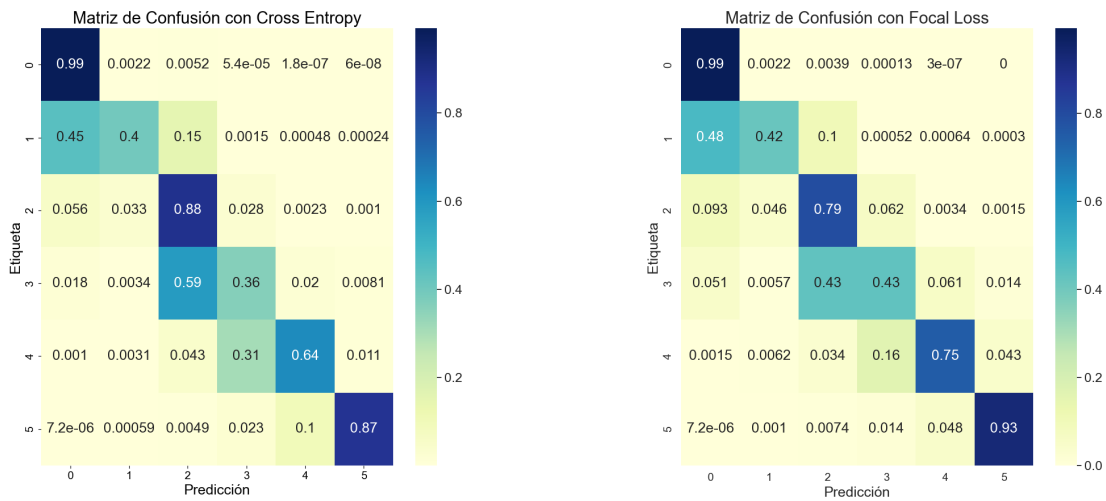


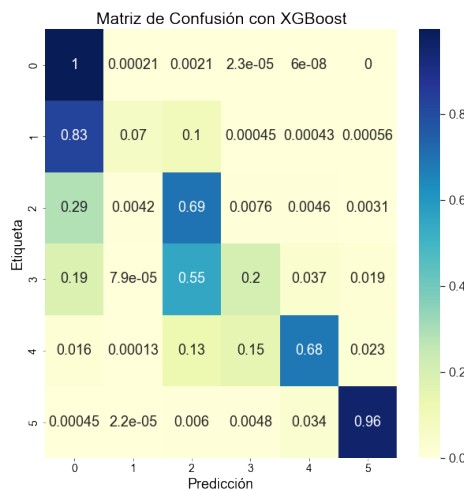
Figura 4.19: (a) Cross Entropy vs Epochs para el primer entrenamiento con 3 categorías, (b) Focal Loss vs Epochs para el segundo entrenamiento con 6 categorías.

Al igual que en la clasificación anterior, el conjunto de figuras 4.20 contiene las matrices de confusión para 6 categorías con Cloud-Net y XGBoost. Los resultados difieren enormemente de los obtenidos previamente. Las categorías intermedias son difícilmente identificadas por ambos algoritmos, con la excepción de la categoría 2 para Cloud-Net entrenada con Cross Entropy. A su vez, las dos categorías extremas, No Lluvia y Lluvia > 30 mm/h, tienen muy buenos resultados, en especial para la red Cloud-Net entrenada con Focal Loss y para XGBoost. Vale recordar que XGBoost no tiene en cuenta la vecindad, sólo contempla la información del píxel individual. Finalmente, es evidente la tendencia de los algoritmos de predecir los píxeles de la categoría 1 como píxeles de No Lluvia, lo cual sugiere una dificultad para establecer el primer umbral de clasificación.



(a)

(b)



(c)

Figura 4.20: Matriz de confusión para 6 categorías con (a) Cloud-Net y Cross Entropy, (b) Cloud-Net y Focal Loss, (c) XGBoost

En las figuras 4.21 se observan las predicciones con las 6 categorías de lluvia para las 17:10 UTC en la región 13. Una vez más, Cloud-Net hace un mejor esfuerzo en encontrar los cúmulos aislados poco intensos pero, a diferencia del caso de 3 categorías de la figura 4.18, Focal Loss no tiene mayor éxito que Cross Entropy. Si se puede apreciar una mayor atención al detalle en los núcleos principales de precipitación, donde la categoría 4 (regiones con verde más claro) se parece más a la etiqueta de QPE.

En las figuras 4.22 se observan las predicciones correspondientes a las 23:30 UTC en la región 8. Se trata de una imagen con una gran presencia de píxeles de lluvia torrencial. Las predicciones con Cloud-Net y XGBoost obtienen mejores resultados, con relativa similitud

entre sí. Se evidencia que todos los modelos predicen muy bien los núcleos principales con las precipitaciones mayores pero fallan en distinta medida respecto a los núcleos secundarios. Estos son los que intervienen en los errores de la matriz de confusión de la figura 4.20.




Figura 4.21: (a) Etiqueta de Test (QPE) y visualización de predicciones para 6 categorías, para las 17:10 UTC, 16/01/2021 en la región 13, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost






Figura 4.22: (a) Data Real y visualización de predicciones para 6 categorías, en ubicación de lluvias intensas, para las 23:30 UTC, 16/01/2021 en la región 8, con (b) Cloud-Net y Cross Entropy, (c) Cloud-Net y Focal Loss, (d) XGBoost

Por último, entre las métricas a considerar se incluye la distancia de Hamming. Es útil para identificar la magnitud de los errores de las predicciones de los algoritmos. A su vez, los histogramas sirven para contextualizar los errores y funcionan como un puente entre las matrices de confusión de las figuras 4.20 y las imágenes 4.21 y 4.22. Dependiendo del uso propuesto para la red neuronal, las diferencias entre categorías vecinas intermedias puede no ser considerado una complicación. A modo de ejemplo se muestran los histogramas correspondientes a Focal Loss. En las figuras se evidencia la diferencia de órdenes entre los módulos de los errores y la clara tendencia de la red Cloud-Net a subestimar las intensidades de lluvia. En la sección 5.1 del apéndice se pueden encontrar los gráficos correspondientes a Cross Entropy y XGBoost. A pesar de existir diferencias entre los valores, los resultados de los 3 histogramas se asemejan mucho entre sí, en especial los de Cloud-Net.



(a)



(b)

Figura 4.23: (a) Histograma de distancias entre la predicción y la etiqueta real, sin el módulo y sin incluir el valor 0, (b) Histograma de distancias entre la predicción y la etiqueta real, con el módulo y en escala logarítmica. Ambos gráficos corresponden a Cloud-Net con Focal Loss.

Capítulo 5

Conclusiones

Se realizó un análisis integral del producto QPE de precipitaciones en una porción importante del continente sudamericano para la primera mitad del mes de enero de 2021.

Primero se contabilizaron los píxeles de lluvia por horario para las distintas categorías de intensidades de lluvia entre los 17°S hasta los 39°S y entre los 49°W y los 73°W. Además, se comprobó la diferencia en órdenes de la presencia de píxeles de “No Lluvia” respecto a los de “Lluvia” y se observó la presencia de intervalos de picos marcados de lluvia alternados con valles.

Luego, se dividió al territorio en 25 regiones, se identificaron los días de mayor cantidad de lluvia y las intensidades predominantes para cada región. Esta parte del trabajo tuvo el fin de verificar si el producto QPE sigue las tendencias de precipitaciones previamente registradas por científicos para cada región.

Se comparó visualmente el algoritmo QPE con los productos RGB *Day Microphysics* y *Day Convective Storm* con resultados de interpretación mixtos. Por un lado, se asoció a las lluvias más intensas con la presencia de nubes conformadas de partículas de hielo, pero no queda muy en clara la identificación inmediata de zonas de convectividad con los píxeles de lluvia más intensas predichos por el algoritmo QPE.

Se accedió a información del 16/01/2021 de pluviómetros en el territorio argentino para comparar con el mapa de lluvia acumulada en un día del producto QPE. El producto QPE tiende a sobrestimar algunos sectores y tiene dificultad para identificar la caída de lluvia poco intensa en algunos puntos (figura 4.11). Hay que tener en cuenta que estos algoritmos pueden llegar a ser optimizados de acuerdo a los procesos de precipitaciones en el hemisferio norte, más precisamente en la región de CONUS, y que existen estudios previos que confirman la sobrestimación del producto QPE en sectores con mucha lluvia acumulada (posible convectividad) y la subestimación en sectores con lluvias acumuladas menos intensas[65].

Se logró entrenar la red neuronal convolucional Cloud-Net el mediante aprendizaje supervisado con un conjunto de datos previamente procesado, tanto en la transformación de los canales del satélite GOES-16 en temperaturas de brillo, como en la categorización de las etiquetas por intensidades de lluvia.

Primero se llevó a cabo una clasificación binaria con 2 funciones de pérdida distintas: Dice Loss y Tversky Loss. En ambos casos se obtuvieron resultados de precisión superiores al 89 % para las categorías de “No Lluvia” y “Lluvia” y se comprobaron mejores resultados visuales con Tversky Loss.

Luego, se extendió el proceso a una clasificación multicategoría con 3 categorías (No Lluvia, Lluvia < 10 mm/h y Lluvia > 30 mm/h). Se mejoró la convergencia de las curvas de entrenamiento y se usaron dos funciones de pérdida distintas: Cross Entropy y Focal Loss. Se obtuvieron resultados de precisión mayores al 80 % para las 3 categorías y se comprobó que Cloud-Net tiene mejores resultados que el algoritmo XGBoost tanto en las matrices de confusión como visualmente.

Finalmente, se siguió el mismo procedimiento con una clasificación de 6 categorías (se pueden ver los umbrales en la siguiente tabla: 3.2). Con Cloud-Net se obtienen muy buenos resultados para las categorías extremas de “No Lluvia”, con un 99 % de precisión para las dos funciones de pérdida, y de Lluvia > 30 mm/h, con un 87 % de precisión con Cross Entropy y un 93 % de precisión con Focal Loss. Por su parte, XGBoost también obtiene muy buenos resultados para la categoría de Lluvia > 30 mm/h, con un 96 % de precisión.

La red tiene mayor dificultad para identificar los píxeles de las categorías intermedias, sin embargo, con la ayuda de las visualizaciones, de las matrices de confusión y de los gráficos de distancias de error Predicción-Etiqueta, se puede verificar que los errores son principalmente entre categorías vecinas y se evidencia que la red es capaz de aprender la estructura a nivel imagen de las precipitaciones, con muy buenas predicciones de los núcleos principales con precipitaciones mayores y un peor desempeño respecto a los núcleos secundarios. Finalmente, es necesario destacar el mejor desempeño de las predicciones para el evento de la región 8 (predominancia de intensidades mayores) respecto al de la región 13 (predominancia de intensidades intermedias).

5.1. Continuaciones del estudio

Este trabajo funciona principalmente como una muestra de lo que se puede desarrollar en la intersección entre el estudio de fenómenos atmosféricos como la lluvia y el aprendizaje automático.

Un primer paso para la continuación de estudio es el reemplazo del producto QPE por información de etiqueta más confiable. Todas las alternativas tienen sus dificultades: la información de MW tiene menor resolución temporal (horas) y espacial (~ 16 km), se requiere una red muy densa de pluviómetros interconectados para optimizar la interpolación y en el caso de los radares meteorológicos se necesita una actualización continua de varios días, sin faltante de píxeles para el entrenamiento de la red neuronal. Cabe recordar que la red Cloud-Net es una red neuronal convolucional, por lo que la ausencia de un píxel puede significar el descarte de la imagen completa. A su vez, todas estas alternativas tienen en común que provienen

de fuentes distintas al satélite GOES-16, por lo que es necesario un chequeo constante de las geolocalizaciones y de las escalas.

Por estas limitaciones, la idea de una red neuronal entrenada para grandes porciones del planeta no parece ser posible en una primera instancia (discusión inicial en la subsección 3.1.3). Un primer paso adecuado sería un estudio de las mejores alternativas en la provincia de Córdoba, tanto con pluviómetros como con radares meteorológicos en suelo.

A su vez, es posible adaptar a la red neuronal Cloud-Net para regresión. Para ello, por el mismo motivo expuesto en este trabajo de evitar tener categorías demasiado predominantes, sería necesario almacenar y procesar muchos más días que los utilizados en este trabajo (~ 350 GB), para poder tener más alternativas de selección y no subrepresentar ningún rango de intensidad de lluvia.

A su vez, la idea de clasificar no se debió solamente a una reducción de las exigencias de almacenamiento. En este trabajo se verificó que tanto Cloud-Net como XGBoost producen muy buenos resultados con la categorías extremas de Lluvia > 30 . Estos casos pueden estar asociados a otros fenómenos de relevancia científica y social como el granizo, actividad eléctrica, las inundaciones o el derrumbe de terreno próximo a una carretera, entre otros.

Finalmente, en el caso que también se crea necesario mejorar los resultados de las categorías intermedias, se puede plantear a los umbrales de intensidades de lluvia como “hiperparámetros” ajustables de la red, con el objetivo de minimizar la función de pérdida elegida. También se puede intentar relacionar los umbrales de las intensidades de lluvia con las clases de nubes mencionadas en la tabla 2.1. En FAMAFA, la doctoranda Paula Romero Jure entrenó un clasificador de forma supervisada mediante redes neuronales artificiales con el fin de que sea capaz de elaborar mapas temáticos de los tipos de nubes[66]. A partir de ambos trabajos se podría profundizar en la vinculación entre el aprendizaje automático y estudios de características importantes de nubes.

Apéndice

Reportes de Clasificación

Categoría	precision	recall	f1-score	support
0.0	0.993847	0.988400	0.991116	1.724377e+07
1.0	0.844060	0.911203	0.876348	1.188232e+06
accuracy	0.983423	0.983423	0.983423	9.834232e-01
macro avg	0.918954	0.949802	0.933732	1.843200e+07
weighted avg	0.984191	0.983423	0.983718	1.843200e+07

Figura 5.1: Reporte de Clasificación de Cloud-Net con Dice Loss

Categoría	precision	recall	f1-score	support
0.0	0.992728	0.990026	0.991375	1.724377e+07
1.0	0.860755	0.894752	0.877424	1.188232e+06
accuracy	0.983884	0.983884	0.983884	9.838840e-01
macro avg	0.926741	0.942389	0.934400	1.843200e+07
weighted avg	0.984220	0.983884	0.984029	1.843200e+07

Figura 5.2: Reporte de Clasificación de Cloud-Net con Tversky Loss

Categoría	precision	recall	f1-score	support
0.0	0.991633	0.994194	0.992912	1.676733e+07
1.0	0.828687	0.796481	0.812265	8.583650e+05
2.0	0.876719	0.846663	0.861429	2.902110e+05
accuracy	0.982331	0.982331	0.982331	9.823315e-01
macro avg	0.899013	0.879113	0.888868	1.791590e+07
weighted avg	0.981964	0.982331	0.982127	1.791590e+07

Figura 5.3: Reporte de Clasificación de Cloud-Net con Cross Entropy y 3 Categorías

Categoría	precision	recall	f1-score	support
0.0	0.993842	0.991422	0.992630	1.676733e+07
1.0	0.787550	0.857526	0.821049	8.583650e+05
2.0	0.923482	0.810679	0.863412	2.902110e+05
accuracy	0.982079	0.982079	0.982079	9.820793e-01
macro avg	0.901624	0.886542	0.892364	1.791590e+07
weighted avg	0.982818	0.982079	0.982317	1.791590e+07

Figura 5.4: Reporte de Clasificación de Cloud-Net con Focal Loss y 3 Categorías

Categoría	precision	recall	f1-score	support
0.0	0.986546	0.992742	0.989635	1.676733e+07
1.0	0.763663	0.722491	0.742507	8.583650e+05
2.0	0.944218	0.752173	0.837325	2.902110e+05
accuracy	0.975897	0.975897	0.975897	9.758974e-01
macro avg	0.898143	0.822469	0.856489	1.791590e+07
weighted avg	0.975182	0.975897	0.975327	1.791590e+07

Figura 5.5: Reporte de Clasificación con XGBoost y 3 Categorías

Categoría	precision	recall	f1-score	support
0.0	0.992376	0.992575	0.992475	1.676733e+07
1.0	0.606227	0.396838	0.479678	2.121040e+05
2.0	0.652382	0.880231	0.749370	5.180460e+05
3.0	0.638041	0.362231	0.462111	2.035690e+05
4.0	0.711642	0.635241	0.671275	7.537300e+04
5.0	0.975293	0.870817	0.920099	1.394840e+05
accuracy	0.972660	0.972660	0.972660	9.726599e-01
macro avg	0.762660	0.689655	0.712501	1.791590e+07
weighted avg	0.972633	0.972660	0.971434	1.791590e+07

Figura 5.6: Reporte de Clasificación de Cloud-Net con Cross Entropy y 6 Categorías

Categoría	precision	recall	f1-score	support
0.0	0.990458	0.993786	0.992119	1.676733e+07
1.0	0.583766	0.415504	0.485468	2.121040e+05
2.0	0.697693	0.794175	0.742814	5.180460e+05
3.0	0.644484	0.434688	0.519193	2.035690e+05
4.0	0.729772	0.751489	0.740472	7.537300e+04
5.0	0.948948	0.929770	0.939261	1.394840e+05
accuracy	0.973297	0.973297	0.973297	9.732974e-01
macro avg	0.765854	0.719902	0.736555	1.791590e+07
weighted avg	0.971827	0.973297	0.972068	1.791590e+07


Figura 5.7: Reporte de Clasificación de Cloud-Net con Focal Loss y 6 Categorías

Categoría	precision	recall	f1-score	support
0.0	0.978739	0.997669	0.988113	1.676733e+07
1.0	0.721598	0.069923	0.127492	2.121040e+05
2.0	0.667166	0.694050	0.680343	5.180460e+05
3.0	0.718357	0.204805	0.318738	2.035690e+05
4.0	0.777057	0.683003	0.727001	7.537300e+04
5.0	0.948222	0.955156	0.951677	1.394840e+05
accuracy	0.967243	0.967243	0.967243	9.672427e-01
macro avg	0.801856	0.600768	0.632227	1.791590e+07
weighted avg	0.962640	0.967243	0.960037	1.791590e+07


Figura 5.8: Reporte de Clasificación con XGBoost y 6 Categorías

Distribuciones Temperaturas de Brillo


A modo de ejemplo, se muestran las distribuciones de temperaturas de brillo de las bandas 8 y 15 para todas las intensidades de lluvia. El principal objetivo de estos gráficos es identificar el desplazamiento de los picos de acuerdo a la intensidad de lluvia correspondiente.




(a)




(b)




(c)



(d)



(e)



(f)

Figura 5.9: Distribuciones de Temperaturas de Brillo de la Banda 8 para las 6 categorías de lluvia

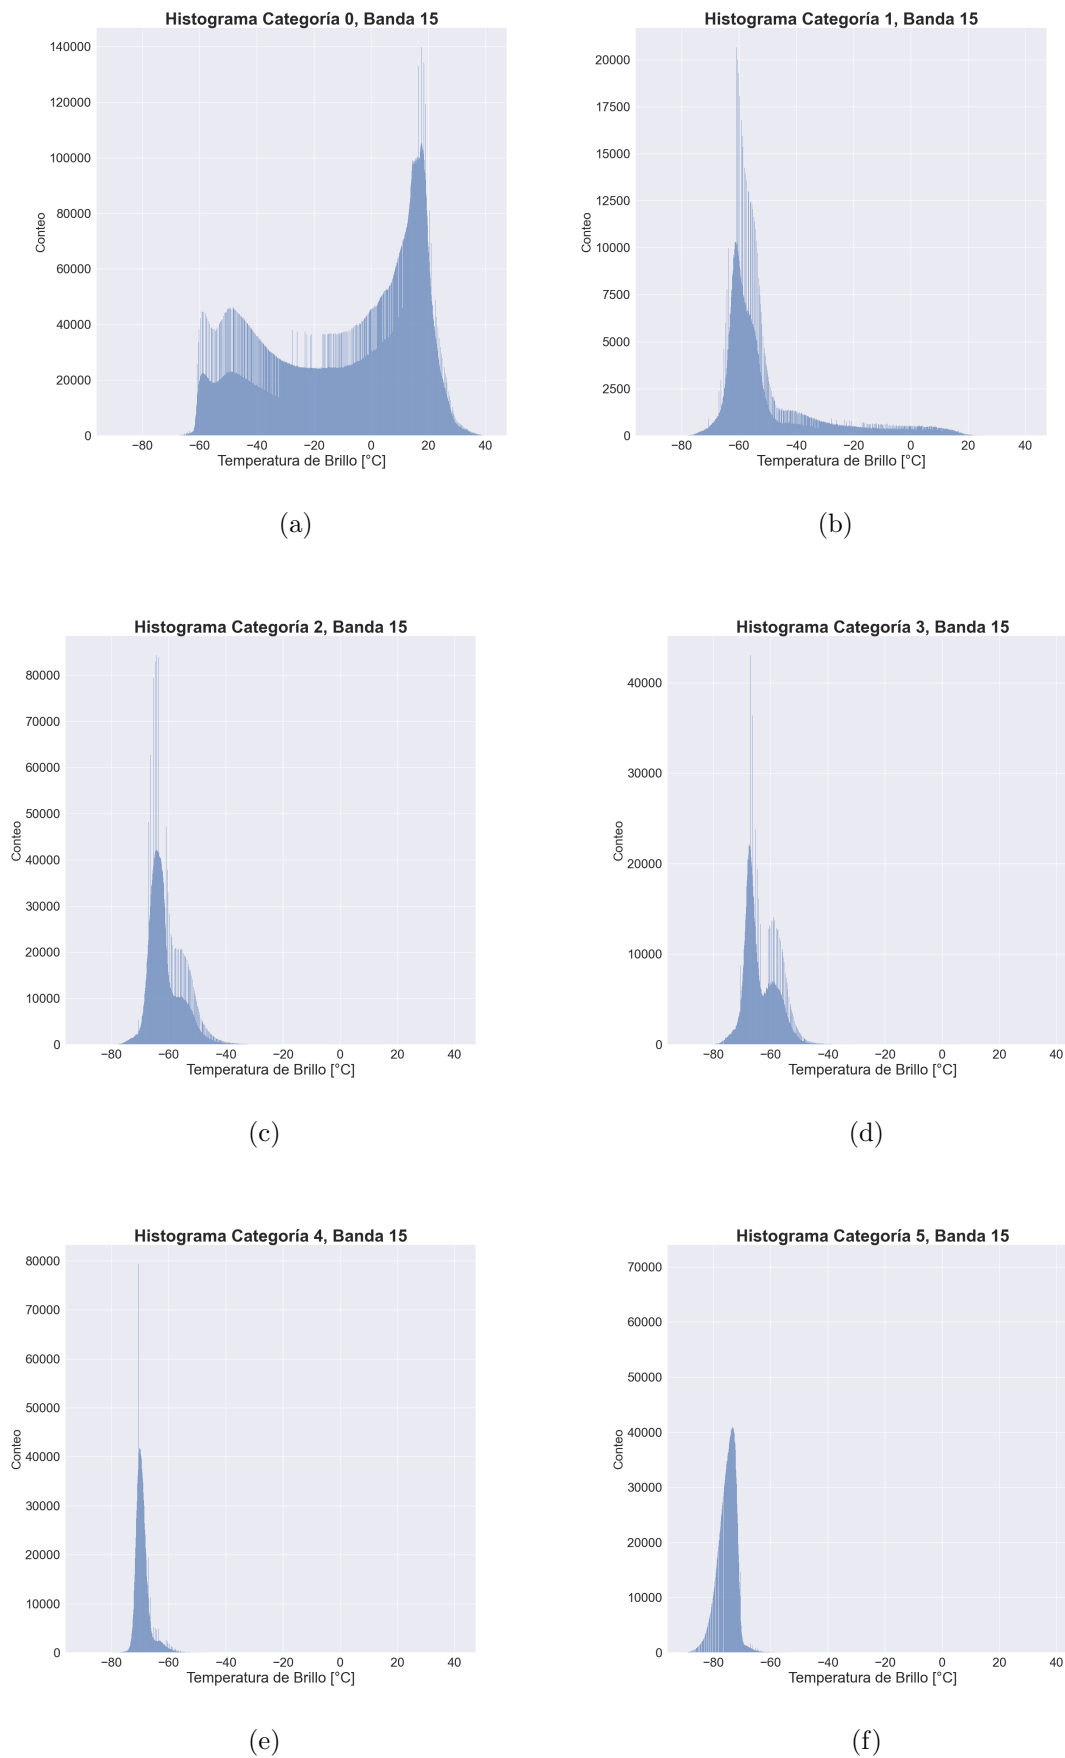


Figura 5.10: Distribuciones de Temperaturas de Brillo de la Banda 15 para las 6 categorías de lluvia

Histogramas de Hamming

En las figuras 4.23 se presenta a modo de ejemplo los resultados de Hamming para el caso de Cloud-Net entrenada con Focal Loss. En las figuras 5.11 se muestran los resultados restantes, correspondientes a Cloud-Net con Cross Entropy y a XGBoost.

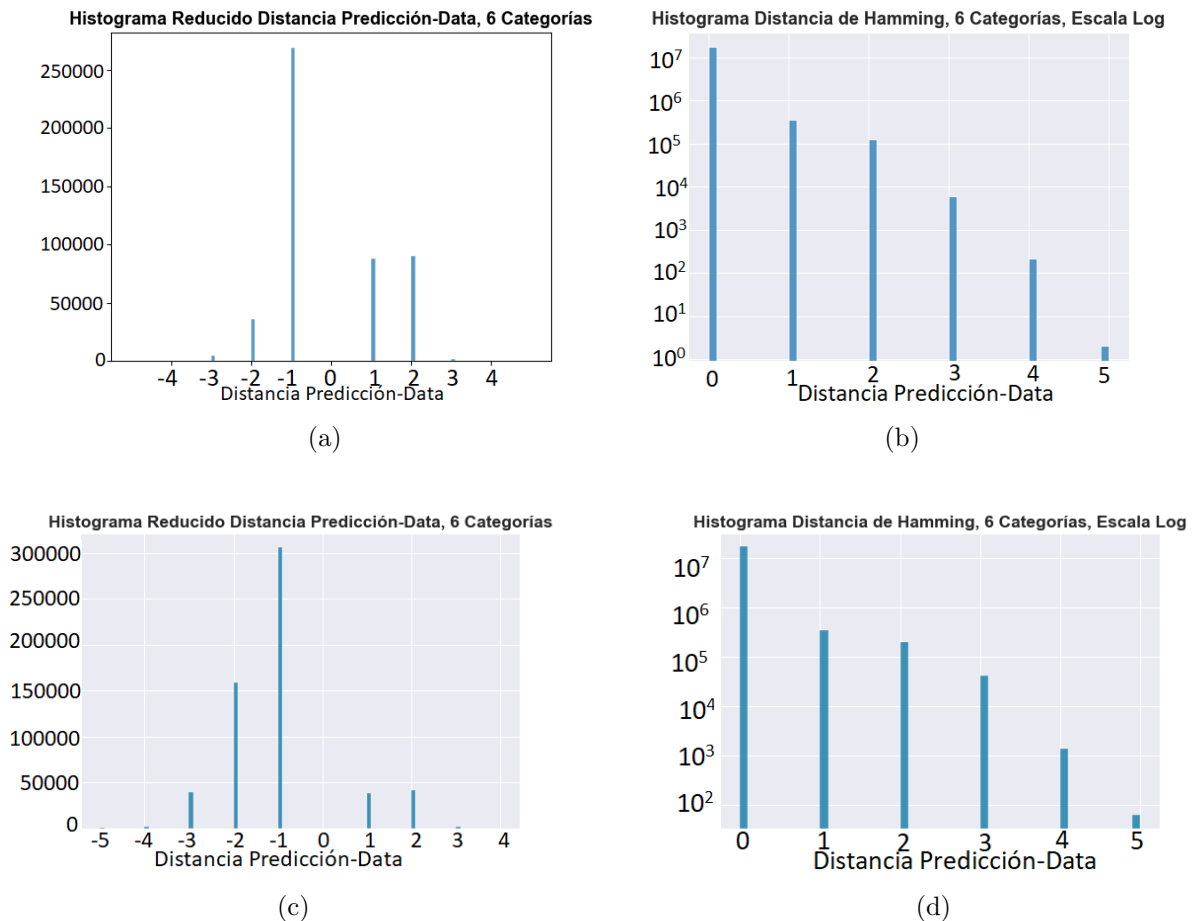


Figura 5.11: (a y c) Histograma de distancias entre la predicción y la etiqueta real, sin el módulo y sin incluir el valor 0, (b y d) Histograma de distancias entre la predicción y la etiqueta real, con el módulo y en escala logarítmica. (a y b) corresponden a Cloud-Net con Cross Entropy y (c y d) corresponden a XGBoost.

Agregado Información de Pluviómetros de Chaco

En el proceso de la elaboración de la presentación del trabajo se decidió revisar particularmente la región de mucha lluvia acumulada en la figura 4.11. Para ello, se accedió a información de pluviómetros provista por la policía de Chaco ¹ y se obtuvo la siguiente figura:

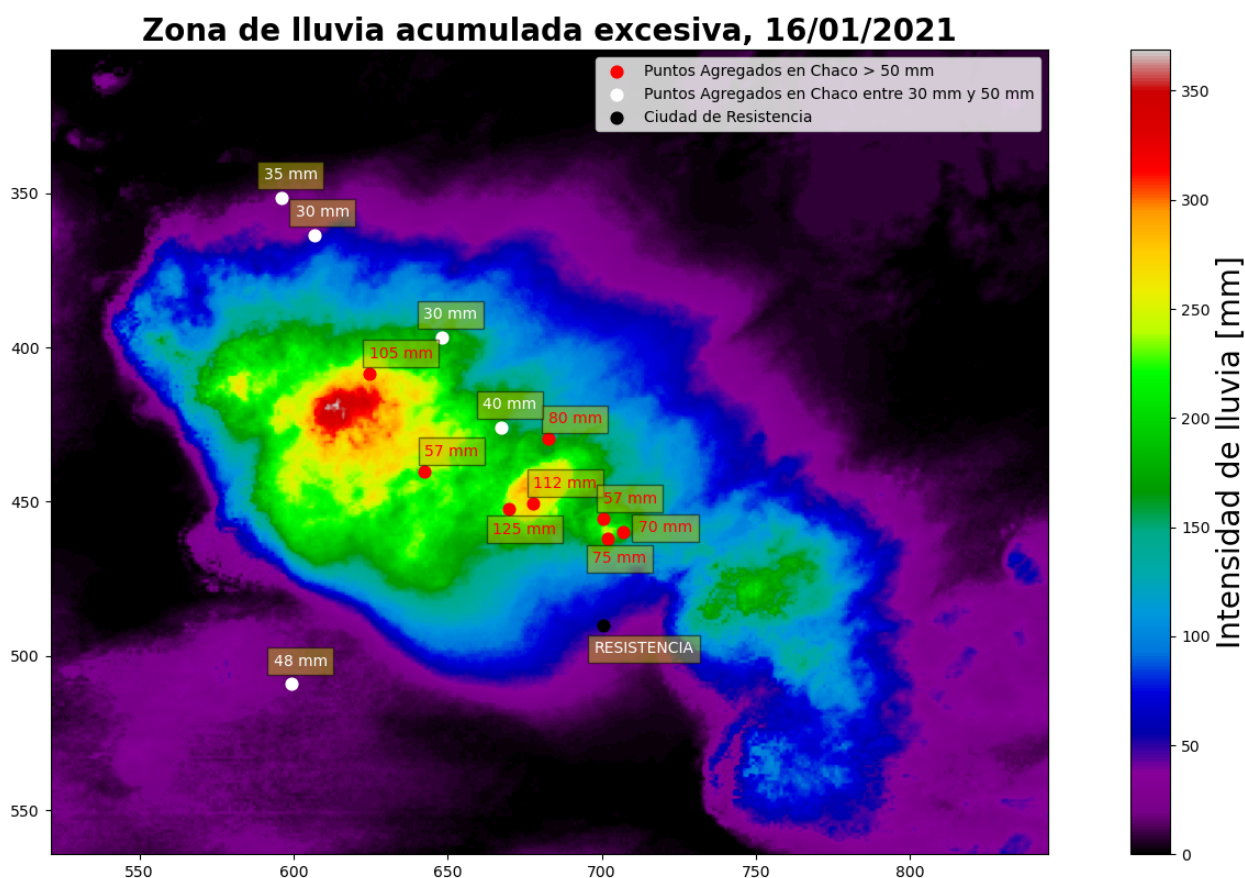


Figura 5.12: Zoom en la región de mucha precipitación. Lluvia recolectada a las 7 ART del día 17/01/2021. Los puntos rojos y blancos corresponden a la información de los pluviómetros y el mapa de colores a la información del QPE

En ella, se ve que los puntos rojos de información de suelo mayor a 50 mm caídos en un día corresponden a los núcleos más intensos previstos por el QPE y se observa la presencia de los puntos blancos de mediana intensidad en los bordes azules y naranjas del mapa de colores del QPE. A pesar de existir un factor de diferencia entre las predicciones del QPE y la información de suelo, en especial en los puntos de más lluvia, la correlación entre ambas es mucho mayor a la previamente establecida con la información del Servicio Meteorológico Nacional de la figura 4.11.

¹Informe de la policía de Chaco del día 17/01/2021: <https://policia.chaco.gob.ar/index.php/ecmLluvias>

Bibliografía

- [1] Robert J. Kuligowski. GOES-R Advanced Baseline Imager (ABI) Algorithm Theoretical Basis Document For Rainfall Rate (QPE). https://www.star.nesdis.noaa.gov/goesr/documents/ATBDs/Baseline/ATBD_GOES-R_Rainrate_v2.6_Oct2013.pdf, 2013. Acceso: 07/11/2022.
- [2] Sorour Mohajerani and Parvaneh Saeedi. Cloud-Net: An End-To-End Cloud Detection Algorithm for Landsat 8 Imagery. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, pages 1029–1032, 07 2019.
- [3] Tianqi Chen and Carlos Guestrin. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 785–794, 08 2016.
- [4] Carleton College. Gibbs Phase Rule: Where it all Begins. https://serc.carleton.edu/research_education/equilibria/phaserule.html. Acceso: 07/11/2022.
- [5] Frank de Morsier. Semi-supervised and unsupervised kernel-based novelty detection with application to remote sensing images. 01 2014.
- [6] Raya-Armenta et al. A Short Review of Radiation-Induced Degradation of III-V Photovoltaic Cells for Space Applications. *Solar Energy Materials and Solar Cells*, 233, 09 2021.
- [7] Vincenzo Levizzani et al. *Satellite Precipitation Measurement, Volume 2*. Springer, 2020.
- [8] Ranjani Kulawardhana. Remote sensing of vegetation: Principles, techniques and applications. By Hamlyn G. Jones and Robin A Vaughan. *Journal of Vegetation Science*, 22:1151–1153, 12 2011.
- [9] Tonmoy Ghosh, Shaikh Anowarul Fattah, and Khabou Wahid. CHOBS: Color Histogram of Block Statistics for Automatic Bleeding Detection in Wireless Capsule Endoscopy Video. *IEEE Journal of Translational Engineering in Health and Medicine*, PP:1–1, 01 2018.
- [10] Mederbal et al. Landscape Pattern of a Semiarid Mediterranean Area Using Remote Sensing Data-Application to the Wilaya of Saida (West of Algeria). *International Journal of Ecology and Development*, 34:145–158, 02 2020.

-
- [11] Latifa Guesmi, H. Fathallah, and Mourad Menif. *Modulation Format Recognition Using Artificial Neural Networks for the Next Generation Optical Networks*. 02 2018.
- [12] Alireza Sarraf Shirazi and Ian Frigaard. SlurryNet: Predicting Critical Velocities and Frictional Pressure Drops in Oilfield Suspension Flows. *Energies*, 14:1263, 02 2021.
- [13] N.S. Johnson, P.S. Vulimiri, A.C. To, X. Zhang, C.A. Brice, Branden Kappes, and Aaron Stebner. Invited review: Machine learning for materials developments in metals additive manufacturing. *Additive Manufacturing*, 36:101641, 10 2020.
- [14] Jeremie Sublime. *Contributions to modern unsupervised learning: Case studies of multi-view clustering and unsupervised Deep Learning*. PhD thesis, 04 2021.
- [15] Tom M. Mitchell. *Machine Learning*. McGraw-Hill Science, 1997.
- [16] Zhang et al. Improving Convection Trigger Functions in Deep Convective Parameterization Schemes Using Machine Learning. *Journal of Advances in Modeling Earth Systems*, 13, 05 2021.
- [17] NOAA & NASA. GOES-R Algorithm Group. <https://www.star.nesdis.noaa.gov/goesr/AWG.php>. Acceso: 07/11/2022.
- [18] Shimizu Akihiro. Introduction to Himawari-8 RGB composite imagery. <https://www.data.jma.go.jp/mscweb/technotes/msctechrep65-1.pdf>. Acceso: 07/11/2022.
- [19] Sadeghi et al. PERSIANN-CNN: Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks - Convolutional Neural Networks. *Journal of Hydrometeorology*, 20, 09 2019.
- [20] Sadeghi et al. Improving near real-time precipitation estimation using a u-net convolutional neural network and geographical information. *Environmental Modelling & Software*, 134:104856, 09 2020.
- [21] Aditya Sai, Somula Ramasubbareddy, Kharisma Govinda, Akriti Saxena, and Pramod Aeluri. Estimating rainfall using machine learning strategies based on weather radar data. *International Journal of Communication Systems*, 33, 09 2020.
- [22] Georgy Ayzel, Tobias Scheffer, and Maik Heistermann. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting. *Geoscientific Model Development*, 13:2631–2644, 06 2020.
- [23] Arthur Moraux, Steven Dewitte, Bruno Cornelis, and Adrian Munteanu. Deep Learning for Precipitation Estimation from Satellite and Rain Gauges Measurements. *Remote Sensing*, 11:2463, 10 2019.

- [24] María Hobouchian, Yanina García Skabar, Daniel Barrera, Daniel Vila, and Paola Salio. Validación de la estimación de precipitación por satélite aplicando la técnica hidroestimador. *Meteorologica vol.42 no.1 Ciudad Autónoma de Buenos Aires*, 42:19–37, 06 2017.
- [25] D.G Andrews. *An Introduction to Atmospheric Physics*. Cambridge University Press, Cambdrige, 2nd edition edition, 2010.
- [26] H.-R. Cho J. V. Iribarne. *Atmospheric Physics*. Springer, Dordrecht, 1st edition edition, 1980.
- [27] Williamson et al. A large source of cloud condensation nuclei from new particle formation in the tropics. *Nature*, 574:399, 10 2019.
- [28] Chongxing Fan, Maiqi Ding, Pei-Syun Wu, and Yaqi Fan. The Relationship between Precipitation and Aerosol: Evidence from Satellite Observation. *arXiv: Atmospheric and Oceanic Physics*, 2018.
- [29] H.R. Pruppacher and J.D. Klett. *Microphysics of Clouds and Precipitation*. Springer, Dordrecht, 2010.
- [30] S.D. Ilcev. *Global Satellite Meteorological Observation (GSMO) Theory, Volume 1*. Springer, 2018.
- [31] W.G. Rees. *Physical Principles of Remote Sensing*. Cambridge University Press, Cambridge, 3rd edition edition, 2015.
- [32] Peter V. Hobbs John M. Wallace. *Atmospheric science: an introductory survey*. Elsevier Academic Press, Amsterdam, Boston, 2nd edition edition, 2006.
- [33] R.R. Kelkar. *Satellite Meteorology*. BS Publications, Hyderabad, 2007.
- [34] Ross Mccluney. *Encyclopedia of Physical Science and Technology*, volume 13, chapter Radiometry and Photometry. Academic Press, 2001.
- [35] Vincenzo Levizzani et al. *Satellite Precipitation Measurement, Volume 1*. Springer, 2020.
- [36] Robert Massom Dan Lubin. *Polar Remote Sensing: Volume I: Atmosphere and Oceans*. Springer, 2006.
- [37] Jim Valenti. GOES R SERIES PRODUCT DEFINITION AND USERS GUIDE. <https://www.goes-r.gov/users/docs/PUG-main-vol1.pdf>. Acceso: 16/11/2022.
- [38] Jim Valenti. 416-R-PUG-L1B-0347 Vol 3. Revision 2.2. <https://www.goes-r.gov/users/docs/PUG-L1b-vol13.pdf>. Acceso: 07/11/2022.
- [39] Jim Valenti. 416-R-PUG-L2 Plus-0349 Vol 5. Revision 2.2. <https://www.goes-r.gov/products/docs/PUG-L2+-vol15.pdf>. Acceso: 07/11/2022.

- [40] Stephen Marsland. *Machine Learning: An Algorithmic Perspective*. CRC Press, 2nd edition, 2015.
- [41] Michael A. Nielsen. *Neural Networks and Deep Learning*. Determination Press, 2013.
- [42] Diederik Kingma and Jimmy Ba. Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*, 12 2014.
- [43] Razvan Pascanu, Guido Montufar, and Y. Bengio. On the number of response regions of deep feed forward networks with piece-wise linear activations. 12 2013.
- [44] Md Hafizur and Md Hafizur Rahman Masum. Visualizing and Understanding Convolutional Networks. 10 2022.
- [45] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. *LNCS*, 9351:234–241, 10 2015.
- [46] Min Lin, Qiang Chen, and Shuicheng Yan. Network In Network. 12 2013.
- [47] Corey Wade. *Hands-On Gradient Boosting with XGBoost and scikit-learn*. Packt Publishing, 2020.
- [48] GOES-R. ABI bands quick information guide. <https://www.goes-r.gov/mission/ABI-bands-quick-info.html>. Acceso: 07/11/2022.
- [49] NOAA. NOAA's comprehensive large array-data stewardship system. <https://www.avl.class.noaa.gov/saa/products/welcome>. Acceso: 07/11/2022.
- [50] John Borchert. Regional Differences in the World Atmospheric Circulation. *Annals of the Association of American Geographers*, 43:14, 03 1953.
- [51] Wang Jiamin, Yuping Guan, Lixin Wu, Xiaodan Guan, Wenju Cai, Jianping Huang, Wenjie Dong, and Banglin Zhang. Changing Lengths of the Four Seasons by Global Warming. *Geophysical Research Letters*, 48, 03 2021.
- [52] Junfei Qiu and Sun Youming. A Research on Machine Learning Methods for Big Data Processing. 01 2015.
- [53] Nationwide Operational Assesment of Hazards. <https://noah.up.edu.ph/>. Acceso: 07/11/2022.
- [54] Bastian Kirsch, Marco Clemens, and Felix Ament. Stratiform and Convective Radar Reflectivity–Rain Rate Relationships and Their Potential to Improve Radar Rainfall Estimates. *Journal of Applied Meteorology and Climatology*, 58, 08 2019.

- [55] Federico Andelsman. Rainfall detection and classification using neural networks. <https://github.com/fandelsman/Rainfall-Detection-and-Classification-using-Neural-Networks>, 2022.
- [56] Shruti Jadon. A survey of loss functions for semantic segmentation. *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, pages 1–7, 10 2020.
- [57] Nabila Abraham and Naimul Khan. A Novel Focal Tversky Loss Function With Improved Attention U-Net for Lesion Segmentation. *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, pages 683–687, 04 2019.
- [58] Zhao et al. Rethinking Dice Loss for Medical Image Segmentation. *2020 IEEE International Conference on Data Mining (ICDM)*, pages 851–860, 11 2020.
- [59] Seyed Sadegh Salehi, Deniz Erdogmus, and Ali Gholipour. Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks. pages 379–387, 09 2017.
- [60] Tsung-Yi Lin, Priyal Goyal, Ross Girshick, Kaiming He, and Piotr Dollar. Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PP:1–1, 07 2018.
- [61] Josh Welty, Susan Stillman, Xubin Zeng, and Joseph Santanello. Increased Likelihood of Appreciable Afternoon Rainfall Over Wetter or Drier Soils Dependent Upon Atmospheric Dynamic Influence. *Geophysical Research Letters*, 47, 06 2020.
- [62] Wan-Ru Huang, Ya-Hui Chang, Liping Deng, and Pin-Yi Liu. Simulation and Projection of Summer Convective Afternoon Rainfall Activities over Southeast Asia in CMIP6 Models. *Journal of Climate*, 34:1–43, 03 2021.
- [63] Curado et al. Modeling the reflection of photosynthetically active radiation in a monodominant floodable forest in the pantanal of mato grosso state using multivariate statistics and neural networks. *Anais da Academia Brasileira de Ciências*, 88:1387–1395, 09 2016.
- [64] Christopher Purr, Erwan Brisson, Heinke Schlünzen, and Bodo Ahrens. Convective rain cell properties and the resulting precipitation scaling in a warm temperate climate. *Quarterly Journal of the Royal Meteorological Society*, 148, 04 2022.
- [65] Luyao Sun, Haonan Chen, Zhe Li, and Lei Han. Cross validation of goes-16 and noaa multi-radar multi-sensor (mrms) qpe over the continental united states. *Remote Sensing*, 13:4030, 10 2021.
- [66] Romero Jure Paula Verónica. Estudios sobre clasificación de tipos de nubes en imágenes de satélites meteorológicos usando procesamiento de imágenes y técnicas de aprendizaje

automatico. Facultad de Matemática, Astronomía, Física y Computación (FAMAF), 03 2022.