

Universidad Autónoma de Querétaro
Facultad de Informática
Doctorado en Ciencias de la Computación

Descriptor de forma para la clasificación de sistemas nubosos en función de la intensidad de lluvia.

TESIS

Que como parte de los requisitos para obtener el grado de

Doctor en Ciencias de la Computación

Presenta:

Iván González García

Directora:

Dra. Ana Marcela Herrera Navarro

Codirector:

Dr. Martín Alfonso Gutiérrez López

Dra. Ana Marcela Herrera Navarro		
Presidente		Firma
Dr. Martín Alfonso Gutiérrez López		
Secretario		Firma
Dr. Jorge Luis Pérez Ramos		
Vocal		Firma
Dr. Daniel Cantón Enríquez		
Suplente		Firma
Dr. Hugo Jiménez Hernández		
Suplente		Firma

Centro Universitario
Querétaro, Qro.
5 de noviembre de 2026

REPOSITORIO INSTITUCIONAL DGBSDI-UAQ

La presente obra está bajo la licencia:
https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es

CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:

Atribución — Usted debe dar crédito de manera adecuada , brindar un enlace a la licencia, e indicar si se han realizado cambios . Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.

NoComercial — Usted no puede hacer uso del material con propósitos comerciales .

SinDerivadas — Si remezcla, transforma o crea a partir del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni medidas tecnológicas que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una excepción o limitación aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como publicidad, privacidad, o derechos morales pueden limitar la forma en que utilice el material.

©Iván González García

All rights reserved.

A mis papás, por todo.

Agradecimientos

Agradezco a la Facultad de Informática de la Universidad Autónoma de Querétaro, mi casa de estudios, por la formación recibida y por brindarme el espacio para desarrollar este trabajo. A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), por la beca otorgada para la realización de mis estudios de doctorado.

A mis directores de tesis, la Dra.Ana Marcela Herrera Navarro y el Dr. M. Alfonso Gutiérrez López, por su guía, su paciencia y la confianza que depositaron en este proyecto desde el principio. Sus observaciones y su acompañamiento en cada etapa fueron fundamentales para llevar esta investigación a buen término.

A mis sinodales, el Dr.Jorge Luis Pérez Ramos, el Dr.Daniel Cantón Enríquez y el Dr.Hugo Jiménez Hernández, por el tiempo dedicado a la revisión de este trabajo.

A mis profesores y coordinadores, la Dra.Diana, el Dr.Acuña y el Dr.Martín, por el seguimiento puntual que dieron a este proceso.

A mis amig@s, por su amistad, sus enseñanzas y su ánimo constante y además que, de una u otra forma, contribuyeron a este trabajo y cuyos nombres no aparecen en estas líneas pero no terminaría de agradecer y voy contra tiempo, les ofrezco mi más sincero agradecimiento.

De manera especial, a Alex, un amigo que ya no está aquí, pero que marcó nuestros caminos. Su recuerdo me acompañó a lo largo de este trabajo.

Y finalmente, a mi familia, por su amor, su apoyo incondicional y por acompañarme en cada paso de este camino.

¿Cómo vas a buscar una cosa cuya naturaleza te es del todo desconocida? ¿cuál de entre las cosas que desconoces es la que pretendes buscar?, y si por azar dieras con ella, ¿cómo sabrías que es lo que buscabas, siendo así que la desconoces?

Platón

Resumen

Esta tesis estudia la relación entre la geometría de los sistemas nubosos y la intensidad de la lluvia, a partir de imágenes satelitales digitales y matrices de precipitación estimada. El problema parte de una limitación conocida: la técnica de Dvorak es la referencia clásica para interpretar la organización morfológica de los ciclones tropicales y estimar su intensidad en términos de viento, pero no fue diseñada para cuantificar precipitación. Queda entonces espacio para construir descriptores geométricos explícitos, interpretables y computacionalmente accesibles, que complementen la lectura visual tradicional y permitan estudiar su asociación con la lluvia.

El trabajo integra dos fuentes documentales: el manuscrito científico centrado en las geometrías de Dvorak y el protocolo de tesis orientado al desarrollo de un descriptor de forma para sistemas nubosos. De ahí se plantea la hipótesis de que los patrones geométricos de los sistemas nubosos se relacionan con la magnitud y frecuencia de las precipitaciones. Para ponerla a prueba se usan imágenes GOES-13, archivos CSV con intensidades de lluvia por píxel y procedimientos de segmentación que aíslan las regiones de precipitación relevantes. Sobre esas regiones se calculan descriptores clásicos de circularidad, redondez y convexidad, además de una propuesta basada en la razón entre perímetro y diámetro.

El trabajo combina procesamiento digital de imágenes, morfología matemática, análisis geométrico y estadística multivariada; en particular, Análisis de Componentes Principales para sintetizar la variabilidad morfológica y explorar su relación con la intensidad de lluvia. El huracán Patricia (2015) es el caso de estudio principal, por su intensidad, la disponibilidad de datos y su relevancia meteorológica. Los resultados muestran que la forma geométrica contiene información útil para caracterizar regiones de lluvia intensa, y respaldan el uso de descriptores morfológicos como apoyo en clasificación, análisis satelital y evaluación hidrometeorológica.

Índice general

Agradecimientos III

Resumen I

1. Introducción **1**
1.1. Contexto general del problema 1
1.2. La forma como variable meteorológica 1
1.3. Relación con la técnica de Dvorak 2

2. Planteamiento de la investigación **3**
2.1. Justificación 3
2.2. Planteamiento del problema 4
2.3. Hipótesis 4
2.4. Objetivo general 4
2.5. Objetivos específicos 5
2.6. Alcances y aportaciones del estudio 5

3. Marco teórico **6**
3.1. Procesamiento de imágenes digitales 6
3.2. Morfología matemática y segmentación 6
3.3. Métricas y descriptores geométricos 7
3.3.1. Motivación geométrica adicional: ancho constante, perímetro y diámetro. 7
3.4. La técnica de Dvorak y su evolución 9
3.5. Sistemas nubosos, precipitación satelital y percepción remota 11

4. Materiales y métodos **13**
4.1. Diseño metodológico 13
4.2. Proceso metodológico general 13
4.3. Recursos humanos y materiales 14
4.4. Base de datos 14

4.5. Huracán Patricia 15
4.6. Hidroestimador 16
4.7. Análisis de Componentes Principales 17
4.8. Agrupamiento *k-means* 17

5. Geometría de las variables **19**
5.1. Escala y cálculo de descriptores 20
5.2. Descriptores clásicos 20
5.2.1. Comparación entre área y perímetro 20
5.2.2. Comparación entre área y diámetro 20
5.2.3. Relación entre radios 20
5.2.4. Medida de redondez 21
5.2.5. Medición de convexidad 21
5.3. Descriptores propuestos 21
5.4. Formas dentro del sistema nuboso 23

6. Resultados **31**
6.1. Validación cualitativa de la clasificación 37

7. Discusión **39**
7.1. Desarrollos recientes y perspectivas futuras 39
Desarrollos recientes y perspectivas futuras 39

8. Conclusiones **41**

A. Análisis de sensibilidad **42**

B. Descripción del algoritmo `AnalysisRainGOES13` **44**

C. Descripción general del proceso computacional **46**
C.1. Planteamiento 46
C.2. Las tres etapas del proceso 46
C.3. Los datos utilizados 49

D. Artículo publicado **50**

Bibliografía **73**

Índice de tablas

5.1. Variables geométricas y pluviométricas utilizadas en el análisis. 19
5.2. Ecuaciones de los parámetros geométricos utilizados. 23
5.3. Descriptor de forma. 25
5.4. Factores que caracterizan la morfología de las nubes. 29

6.1. Proyecciones en dos componentes. 32
6.2. Proyecciones en tres componentes principales. 32
6.3. Resumen comparativo de los análisis ACP para cada variable objetivo. 33
6.4. Valores de R^2 para sistemas nubosos con tasas de lluvia mayores a 50 mm/h y objetos mayores de 20 píxeles. 36

A.1. Número de objetos detectados por intensidad de lluvia y tamaño de ventana. 42
A.2. Porcentaje de varianza explicada (ACP de 2 componentes) para Rain, Mode y Max por intensidad de lluvia y tamaño de ventana. 42
A.3. Vista previa del conjunto de datos: 2090 registros y 8 variables. 43

C.1. Programas que integran el proceso, con sus insumos y productos. 49

Índice de figuras

3.1. Representación del ancho de una figura convexa en una dirección dada. 8
3.2. Triángulo de Reuleaux como ejemplo de figura de ancho constante. . . . 8
3.3. Esquema general de patrones asociados con la técnica de Dvorak. . . . 10

4.1. Clasificación de escalas y factores de riesgo de daños sugerida para la región de América Latina y el Caribe (**?**) 16

5.1. Áreas de lluvia extrema ($\geq$ 50 mm/h) en el huracán Patricia, 19 de octubre de 2015, 09:15 UTC. 24
5.2. Segmentación de regiones con mayor intensidad de lluvia. Los contornos rojos delimitan las áreas identificadas por el algoritmo como regiones con precipitación más intensa. 25

6.1. Visualización bidimensional de k-means en el espacio del ACP. 31
6.2. Visualización tridimensional de k-means en el espacio del ACP. 33
6.3. Círculos de correlación correspondientes a la intensidad media, la moda y el máximo de precipitación. 34
6.4. Resultado visual de la clasificación. La similitud de las nubes dentro de cada categoría sugiere coherencia morfológica intraclase. 37

C.1. Flujo general del proceso: de los mapas de intensidad de lluvia a los grupos de sistemas nubosos. Los recuadros azules corresponden a los datos que circulan entre etapas y los grises a los programas documentados en cada apéndice. 48

Capítulo 1

Introducción

1.1. Contexto general del problema

La intensidad de la lluvia asociada a ciclones tropicales y sistemas nubosos es uno de los problemas más relevantes de la meteorología operativa, la percepción remota y la gestión del riesgo. En muchas regiones, la lluvia intensa causa impactos más inmediatos que el propio viento: inundaciones, deslizamientos, daños a infraestructura, afectaciones que se acumulan a escala local y regional. Sin embargo, la relación entre la forma geométrica de un sistema nuboso y la precipitación que produce no está plenamente caracterizada, a pesar de que las imágenes satelitales muestran esos patrones morfológicos de manera directa, casi en tiempo real.

Este trabajo parte de una idea sencilla: la geometría de una nube no es solo una descripción visual, sino una fuente de información que puede cuantificarse. Si una forma satelital puede segmentarse, medirse y compararse, entonces pueden construirse descriptores geométricos que ayuden a estudiar su relación con la intensidad de lluvia. Esta perspectiva conecta el procesamiento de imágenes, la morfología matemática, el análisis estadístico y la meteorología aplicada.

1.2. La forma como variable meteorológica

El interés por la forma de las tormentas no es únicamente descriptivo. La organización de las bandas, la compacidad del núcleo nuboso, la simetría del sistema y la presencia de un ojo bien delimitado reflejan procesos dinámicos internos del ciclón. Dicho de otro modo, la forma observada se relaciona con el grado de organización convectiva, con la interacción entre bandas externas e internas y con la distribución espacial de la humedad y la precipitación. Por eso la morfología de una tormenta puede tratarse como una variable relevante, y no solo como un rasgo visual accesorio.

En la literatura reciente se ha reforzado el uso de imágenes satelitales, productos de precipitación y métodos automáticos de interpretación fina para estudiar ciclones tropicales y lluvias extremas (**?????**). Estos modelos, sin embargo, no eliminan la necesidad de medidas geométricas explícitas e interpretables: pueden servir de puente entre la interpretación física del fenómeno y los procedimientos automáticos de clasificación o predicción.

1.3. Relación con la técnica de Dvorak

Una referencia obligada en el análisis morfológico de ciclones tropicales es la técnica de Dvorak, desarrollada a partir de imágenes satelitales para estimar la intensidad del ciclón en términos de viento (**????**). Se basa en configuraciones visuales bien conocidas que representan distintos estados de organización estructural. Que siga usándose después de tantos años demuestra que la forma sí contiene información valiosa sobre el sistema.

El método clásico, sin embargo, se concibió para estimar viento y presión, no precipitación. La distinción importa: un sistema puede mostrar una configuración morfológica determinada sin que eso implique una cuantificación precisa de la lluvia. Esta tesis retoma la intuición geométrica de Dvorak, pero la reorienta hacia otro objetivo: estudiar si ciertos descriptores de forma se asocian con la magnitud y frecuencia de las precipitaciones. No se trata de sustituir la técnica clásica, sino de extenderla conceptualmente, usando la geometría como variable cuantificable para el análisis hidrológico.

Capítulo 2

Planteamiento de la investigación

2.1. Justificación

A pesar de los avances en percepción remota, segmentación automática y aprendizaje profundo aplicados a imágenes meteorológicas, todavía no existe una metodología que relacione de forma directa la intensidad de lluvia con la geometría de los sistemas nubosos. La técnica de Dvorak sigue siendo la referencia clásica para describir patrones morfológicos en ciclones tropicales y estimar su intensidad en términos de viento, pero deja abierta la posibilidad de incorporar indicadores geométricos objetivos e interpretables que complementen la lectura visual y favorezcan el análisis hidrológico (**????**).

Sensores satelitales más precisos, productos de precipitación multifuente y metodologías basadas en inteligencia artificial han mejorado el análisis de ciclones tropicales y sistemas nubosos. Aun así, persisten diferencias entre algoritmos para detectar máximos de precipitación, representar estructuras espaciales extremas y describir con claridad la organización morfológica de los sistemas precipitantes (**?????**). Por eso los descriptores geométricos simples e interpretables conservan vigencia: pueden complementar a los modelos complejos aportando medidas explícitas de compacidad, redondez, elongación u organización espacial.

Una metodología de este tipo puede contribuir al análisis temprano de lluvia extrema, a la clasificación automática de objetos nubosos y al diseño de herramientas de apoyo para pronóstico y gestión del riesgo. También aporta, del lado teórico, al estudio de la relación entre forma, medida y fenómenos hidrometeorológicos, vinculando procesamiento de imágenes, geometría y análisis estadístico.

2.2. Planteamiento del problema

El problema central de esta investigación es determinar si la forma geométrica de los sistemas nubosos, observada a partir de imágenes satelitales digitales y matrices de precipitación, contiene información suficiente para caracterizar y clasificar eventos de lluvia intensa. Un antecedente importante es el trabajo de Molina Aguilar, donde se asocian imágenes satelitales digitales con matrices de intensidad de lluvia estimadas mediante el Hidroestimador (**?**). De ahí surge la posibilidad de construir descriptores geométricos que no solo describan la forma, sino que permitan explorar su relación con la precipitación.

Las preguntas que orientan esta tesis son: ¿existe una relación entre la forma geométrica de un sistema nuboso y el régimen de precipitación asociado? ¿Qué parámetros geométricos son más informativos para explicar la intensidad de lluvia? ¿Es posible proponer un descriptor simple, interpretable y computacionalmente accesible que complemente las métricas reportadas en la literatura? Se estudian en el contexto de sistemas nubosos asociados a ciclones tropicales, con énfasis en el huracán Patricia (2015) como caso de estudio principal.

2.3. Hipótesis

La hipótesis de trabajo se formula de la siguiente forma:

> *Los patrones geométricos de los sistemas nubosos se relacionan con la magnitud y frecuencia de las precipitaciones.*

Esto se interpreta así: si la forma del sistema nuboso contiene información estructural sobre la organización de la precipitación, entonces debe ser posible detectarla mediante descriptores geométricos calculados sobre regiones segmentadas y contrastados con medidas de lluvia como el promedio, la moda y el valor máximo.

2.4. Objetivo general

Desarrollar un descriptor geométrico de forma, a partir del procesamiento de imágenes digitales satelitales y matrices de intensidad de lluvia, para caracterizar y clasificar sistemas nubosos en relación con la intensidad de precipitación.

2.5. Objetivos específicos

- Organizar la base de datos de imágenes satelitales y de intensidad de lluvia asociada a sistemas nubosos.
- Segmentar las regiones de precipitación relevantes en las imágenes analizadas.
- Calcular descriptores geométricos de las regiones segmentadas.
- Proponer un descriptor geométrico para caracterizar sistemas nubosos en relación con la intensidad de lluvia.
- Implementar computacionalmente el descriptor propuesto y compararlo con descriptores reportados en la literatura.
- Clasificar los sistemas nubosos de acuerdo con sus características geométricas y su intensidad de lluvia.
- Analizar e interpretar los resultados obtenidos mediante herramientas estadísticas multivariadas.

2.6. Alcances y aportaciones del estudio

La tesis busca una metodología reproducible, con utilidad directa en la clasificación y el análisis de imágenes meteorológicas. Sus principales aportaciones son: integrar información satelital y geométrica en una misma ruta de análisis, proponer un descriptor interpretable basado en la relación perímetro-diámetro, compararlo con los descriptores clásicos de forma, y construir una base cuantitativa que relacione la organización morfológica con la intensidad de lluvia. La formulación, además, puede extenderse a otros ciclones, otras cuencas y otros productos satelitales.

Capítulo 3

Marco teórico

3.1. Procesamiento de imágenes digitales

Una imagen digital puede modelarse como una función bidimensional muestreada sobre una rejilla finita, donde a cada par de coordenadas se le asigna un valor de intensidad o color. La imagen queda así representada por un arreglo discreto de píxeles, lo que permite tratar computacionalmente objetos, contornos, regiones y texturas. Siguiendo la clasificación de **?**, el procesamiento de imágenes suele dividirse en tres niveles: primario, con tareas de acondicionamiento como reducción de ruido, realce de contraste y filtrado; intermedio, que cubre segmentación y extracción de características; y avanzado, donde se obtienen inferencias a partir del análisis de la imagen. Este trabajo se ubica principalmente en los niveles intermedio y avanzado, pues segmenta regiones de precipitación y construye descriptores geométricos para su análisis posterior.

3.2. Morfología matemática y segmentación

La morfología matemática da una base formal para estudiar estructuras presentes en una imagen a partir de su forma y su vecindad. Sus orígenes se remontan a resultados clásicos de geometría convexa y teoría de la medida –en particular, a los trabajos de **?** y **?**–, que más tarde dieron pie a los desarrollos de **?** y **?** para el análisis de imágenes. De manera general, muchas operaciones morfológicas pueden verse como operaciones entre conjuntos: si X representa la región de interés y Y un elemento estructurante, entonces la erosión y la dilatación transforman X en nuevos conjuntos que resaltan o modifican propiedades espaciales particulares.

La segmentación es central en este contexto: permite fraccionar una imagen en regiones interpretables y separar los objetos de interés del fondo. Cuando se tiene

conocimiento previo de la forma del objeto, pueden distinguirse metodologías basadas en plantillas, métodos guiados por puntos de referencia o semilla, y estrategias que ajustan métricas, formas o propiedades geométricas para optimizar la detección. En general, la segmentación orientada a forma involucra tres tareas: extracción de puntos de interés, muestreo de contorno y aproximación geométrica. La aportación de esta tesis se sitúa en la última: una representación geométrica cuantitativa para regiones nubosas segmentadas.

3.3. Métricas y descriptores geométricos

La noción de descriptor de forma consiste en asignar valores numéricos a propiedades geométricas de un objeto. Estos valores deben servir para comparar formas entre sí y, en la medida de lo posible, mantenerse invariantes frente a transformaciones irrelevantes para el problema. Vale la pena recordar aquí la noción de métrica: dada una clase de objetos K, una métrica es una función $M : K \times K \to \mathbb{R}$ que satisface simetría, positividad, identidad de los indiscernibles y desigualdad triangular. Esta tesis no siempre trabaja con una métrica en sentido estricto, pero la idea ayuda a entender por qué los descriptores de forma buscan cuantificar diferencias o semejanzas entre objetos.

En procesamiento de imágenes, la circularidad es uno de los conceptos más usados para medir la regularidad geométrica de una región. El enfoque se extiende a otras propiedades –convexidad, redondez, hexagonalidad– y ha dado lugar a numerosos descriptores clásicos y modernos (**??????**). Aquí se retoman varios de esos descriptores y se comparan con una propuesta adicional basada en la razón entre perímetro y diámetro, que se describe más adelante de manera formal.

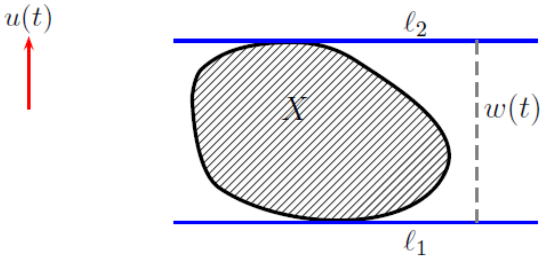
3.3.1. Motivación geométrica adicional: ancho constante, perímetro y diámetro.

Para comprender mejor el sentido de los descriptores propuestos conviene recuperar algunos resultados clásicos de geometría convexa. Si $u(t) = (\cos t, \sin t)$, con $t \in [0, 2\pi]$, representa una dirección, el ancho de una figura convexa en la dirección $u(t)$ se define como la distancia entre las dos rectas soporte ortogonales a esa dirección. En términos de la función soporte $p(t)$, dicho ancho puede escribirse como

$$w(t) = p(t) + p(t + \pi).$$

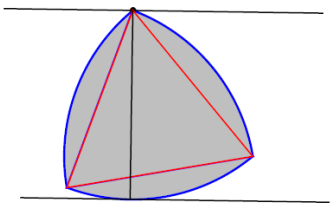
Esta formulación permite relacionar propiedades locales de la frontera con magnitudes globales de la figura y resulta especialmente útil cuando se desea medir qué tan cercana es una forma a un cuerpo de ancho constante.

Figura 3.1
Representación del ancho de una figura convexa en una dirección dada.



El círculo euclidiano satisface que todos sus anchos son iguales, pero no es la única figura con esta propiedad. Un ejemplo clásico es el triángulo de Reuleaux, que muestra que la condición de ancho constante no equivale a ser circunferencia, aunque sí preserva propiedades métricas notables, como la constancia del perímetro para un ancho fijo (**??**).

Figura 3.2
Triángulo de Reuleaux como ejemplo de figura de ancho constante.



En este contexto, el siguiente resultado justifica de manera natural el descriptor basado en la razón entre perímetro y diámetro.

Teorema 3.1. *Toda curva convexa y cerrada, de longitud L y diámetro D, satisface*

$$L \leq \pi D.$$

La igualdad se alcanza si y solo si la curva tiene ancho constante D.

La idea de la demostración parte de la fórmula de Cauchy para la longitud de una curva convexa. Al expresar L como la integral de la suma de anchuras opuestas, se observa que cada anchura está acotada superiormente por el diámetro; al integrar esta cota se obtiene $L \leq \pi D$. La igualdad exige que todas las anchuras coincidan, es decir, que la curva sea de ancho constante (**??**).

Este resultado se complementa con una desigualdad entre área y diámetro.

Teorema 3.2 (Bieberbach)**.** *Si A es el área encerrada por una curva convexa y cerrada de diámetro D, entonces*

$$4A \leq \pi D^2,$$

con igualdad si y solo si la curva es una circunferencia.

La deducción se obtiene combinando el teorema anterior con la desigualdad isoperimétrica. En términos de esta tesis, ambos resultados muestran que el diámetro no solo mide la extensión máxima del objeto, sino que también controla su compacidad global. Por ello, las comparaciones área-diámetro y perímetro-diámetro no son arbitrarias: se apoyan en desigualdades geométricas clásicas que distinguen de manera natural entre formas compactas y formas alargadas o irregulares. Esta motivación teórica refuerza el uso de CAC y RSG como descriptores particularmente adecuados para regiones nubosas segmentadas, donde la regularidad del contorno y la extensión efectiva del sistema son variables físicamente relevantes.

3.4. La técnica de Dvorak y su evolución

La técnica de Dvorak constituye uno de los antecedentes más importantes para esta tesis porque demuestra que la forma observada en imágenes satelitales puede relacionarse con la intensidad de un ciclón tropical. Su formulación original, desarrollada entre las décadas de 1970 y 1980, establece un procedimiento de interpretación visual de patrones nubosos para inferir la intensidad máxima del viento y la presión central del sistema (**???**). Entre los patrones más representativos se encuentran las bandas curvas, la región de *central dense overcast*, el centro embebido y, en ciclones muy organizados, el ojo bien definido y las configuraciones anulares (**?**).

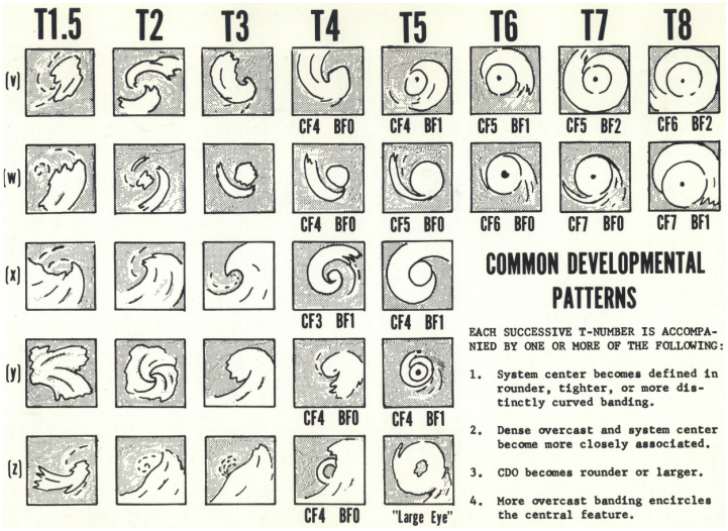
La importancia de este método no reside únicamente en su valor operativo, sino en el hecho de que incorpora una premisa geométrica: la organización espacial de la nubosidad refleja el estado físico del sistema. En otras palabras, la forma no es decorativa, sino informativa. A lo largo del tiempo, la técnica ha sido refinada mediante versiones objetivas y semiautomáticas, como la Técnica Avanzada de Dvorak (ADT), que introducen algoritmos de detección y medición para disminuir la subjetividad del analista (**??**). Asimismo, comparaciones entre agencias y estudios de sesgo han mostrado que la interpretación geométrica puede variar, lo que subraya la conveniencia de trabajar con descriptores explícitos y reproducibles (**???**).

Para esta tesis, la técnica de Dvorak funciona como antecedente conceptual y no solo como contexto histórico. La idea que se retoma es que ciertas configuraciones geométricas condensan información relevante del ciclón; lo que cambia aquí es que el interés se desplaza desde la estimación de viento hacia la caracterización de la precipi-

tación. Por eso el estudio propone medir formas segmentadas, compararlas mediante descriptores geométricos y evaluar si ayudan a explicar la intensidad de lluvia. La investigación queda así en continuidad con la tradición morfológica inaugurada por Dvorak, pero la amplía hacia una lectura hidrológica y estadística de las imágenes satelitales (**?**).

Conviene recordar, de forma resumida, el procedimiento clásico: primero se localiza el centro del ciclón en la imagen satelital; después se identifica el patrón nuboso dominante; a continuación se asignan valores intermedios de intensidad de acuerdo con reglas operativas; finalmente se aplican restricciones temporales y de consistencia para obtener la estimación final. No se trata de replicarlo paso por paso, sino de resaltar que la interpretación geométrica de la nubosidad ha sido históricamente útil en meteorología operativa. La tesis se apoya en Dvorak como antecedente conceptual sólido, pero mueve el foco de la intensidad del viento hacia la organización de la precipitación.

Figura 3.3
Esquema general de patrones asociados con la técnica de Dvorak.



3.5. Sistemas nubosos, precipitación satelital y percepción remota

Los sistemas nubosos presentan una alta variabilidad espacial y temporal de la precipitación, lo que dificulta su medición mediante redes pluviométricas convencionales. En escalas locales pueden registrarse acumulados considerables en pocas horas, mientras que en regiones extensas o de difícil acceso la instalación y mantenimiento de infraestructura de medición es compleja (**?**). Por ello, las estimaciones de precipitación basadas en satélite son una fuente de información clave para el monitoreo de lluvias

intensas y ciclones tropicales (**?**). No reemplazan por completo a las observaciones de superficie, pero sí permiten construir campos espaciales continuos, algo especialmente valioso cuando el fenómeno evoluciona sobre el océano o en regiones con cobertura instrumental limitada.

Más allá del Hidroestimador –empleado en la base de datos de esta tesis y descrito con detalle en el capítulo siguiente–, la comunidad internacional ha desarrollado otros productos operativos de precipitación satelital. El más relevante es la misión Global Precipitation Measurement (GPM), de la NASA y la JAXA, que combina un radar de precipitación de doble frecuencia y un radiómetro de microondas a bordo de un satélite núcleo con una constelación de satélites asociados, para producir estimaciones globales de lluvia (**?**). Su algoritmo de fusión multi-satelital, IMERG, integra información de microondas pasivas e infrarrojo geoestacionario –el mismo tipo de dato que usa el Hidroestimador– para generar campos de precipitación de alta resolución espacial y temporal (**?**). Que existan estos productos globales no resta relevancia a los estimadores regionales: más bien confirma que inferir precipitación a partir de información satelital indirecta sigue siendo un problema abierto, y que la geometría de los sistemas nubosos observados es un ingrediente todavía poco explotado en ese esfuerzo.

En años recientes, el análisis de ciclones tropicales mediante percepción remota ha progresado gracias a sensores satelitales emergentes, comparaciones sistemáticas entre productos de precipitación y enfoques automáticos de interpretación fina de imágenes (**?????**). Estos desarrollos muestran que la automatización y el aprendizaje profundo han ampliado las posibilidades de describir estructuras meteorológicas complejas; pero también hacen evidente la necesidad de conservar medidas geométricas explícitas e interpretables que relacionen la organización morfológica del sistema con la intensidad de lluvia. Algunos estudios recientes ya exploran de manera directa la relación entre forma geométrica y precipitación en huracanes, lo cual refuerza la pertinencia del presente trabajo (**?**).

Capítulo 4

Materiales y métodos

4.1. Diseño metodológico

La investigación sigue un enfoque cuantitativo de corte transversal con un diseño cuasi-experimental. Se combinan herramientas de procesamiento digital de imágenes, segmentación morfológica, estadística descriptiva y análisis multivariado para estudiar la relación entre geometría y precipitación. El componente experimental radica en la construcción y comparación de descriptores geométricos sobre regiones segmentadas; el componente analítico se centra en evaluar qué variables explican mejor la intensidad de lluvia y qué patrones emergen al clasificar los objetos nubosos.

4.2. Proceso metodológico general

El procedimiento desarrollado en esta tesis puede resumirse en las siguientes etapas:

1. **Preprocesamiento de datos de precipitación.** Se cargan matrices de intensidad de lluvia en formato `.CSV`, se organizan temporal y espacialmente y se aplican umbrales para conservar regiones con precipitación significativa.

2. **Segmentación de regiones.** A partir de los umbrales seleccionados se identifican regiones continuas de precipitación, agrupando píxeles adyacentes que pertenecen al mismo sistema nuboso.

3. **Extracción de estadísticas y descriptores.** Para cada región segmentada se calculan propiedades geométricas y estadísticas asociadas con la lluvia, con el fin de construir una representación compacta y comparable de la forma.

4. **Reducción de dimensionalidad y clasificación.** Las variables calculadas se normalizan y se analizan mediante ACP; posteriormente se aplican algoritmos de agrupamiento como k-means para detectar patrones geométricos dominantes.

5. **Interpretación de resultados.** Finalmente, se estudian las componentes principales, los círculos de correlación y las agrupaciones obtenidas para identificar cuáles descriptores explican mejor la variabilidad observada y su relación con la intensidad de precipitación.

4.3. Recursos humanos y materiales

Para la realización de esta investigación se cuenta con dirección y asesoría en áreas de morfología matemática, procesamiento de imágenes e hidrología aplicada. En cuanto a recursos materiales, se emplean bases de datos de imágenes satelitales, archivos de intensidad de lluvia y equipo de cómputo para el procesamiento, análisis y visualización de resultados. Entre los eventos hidrometeorológicos considerados destacan sistemas asociados a ciclones tropicales como Patricia (2015), además de otros casos documentados en trabajos previos que sirven como referencia metodológica.

4.4. Base de datos

El trabajo utiliza una base de datos compuesta por 134 archivos `.CSV`, cada uno con una matriz de intensidad de lluvia de 817×1280 píxeles en mm/h por píxel. Estos archivos provienen del método de procesamiento presentado en **?**, el cual propone una técnica para asociar matrices de intensidad de lluvia con imágenes satelitales digitales mediante el método Hidroestimador.

En dicho trabajo, los materiales consisten en imágenes satelitales digitales adquiridas por el satélite meteorológico geoestacionario GOES-13, el cual cubre México y captura imágenes a intervalos de 15 minutos. Los cuadros de ISD tienen una resolución radiométrica de 8 bits. Cada imagen abarca 817 píxeles en latitud por 1280 píxeles en longitud, con un tamaño de píxel de 2.36 km por lado. Como parte de la metodología de **?**, se emplean conjuntos de datos de estaciones meteorológicas ambientales ubicadas dentro del área de estudio para validar la matriz de intensidad de lluvia por píxel.

La base de datos contiene segmentaciones de imágenes desde las 00:15 h del 22 de octubre de 2015 hasta las 20:15 h del 24 de octubre de 2015. Durante ese periodo, el huracán transitó de categoría I a categoría V y posteriormente regresó a categoría I, con un total de 134 archivos que contienen información de intensidad de lluvia. En este análisis se propone aplicar el ACP para identificar correlaciones entre las variables del conjunto de datos y la variable objetivo. Adicionalmente, el análisis busca identificar las variables que influyen de manera importante en la explicación del fenómeno.

Para reducir el sesgo por pixelación, solo se analizan contornos con un diámetro efectivo de al menos 5 píxeles (aproximadamente un área de 20 píxeles). Este umbral

se utiliza porque las métricas basadas en perímetro o diámetro muestran estabilidad numérica por encima de dicho valor. Este criterio preserva estructuras de precipitación a escala sinóptica y mantiene consistencia en todas las pruebas.

4.5. Huracán Patricia

El caso de estudio de esta investigación se centra en el huracán Patricia, ocurrido del 20 al 24 de octubre de 2015 en la costa del Pacífico mexicano. Este huracán evolucionó hasta categoría 5 en la escala Saffir–Simpson y es considerado uno de los más intensos registrados en términos de presión atmosférica y vientos sostenidos (**?**). En el trabajo de **?** se desarrolla un método para asociar una matriz de intensidad de lluvia con una imagen satelital digital usando el Hidroestimador. Con estas matrices como referencia se construye una proyección del fenómeno meteorológico teniendo en cuenta la intensidad de lluvia. Cada matriz se guarda en un archivo `.CSV` y corresponde a una imagen satelital digital de un instante específico del fenómeno, capturada por GOES-13.

La imagen tiene dimensiones de 817 × 1280 píxeles y cada píxel mide 2.36 km por lado. A partir de la matriz de intensidad se modelan los sistemas nubosos para valores extremos de precipitación. Derivado del trabajo presentado en la Tabla 5 de **?**, solo se seleccionan valores de intensidad de lluvia superiores a 50 mm/h, lo cual produce sistemas nubosos que posteriormente se traducen a imágenes binarias mediante procesamiento. Este proceso genera una imagen binaria con la forma del sistema nuboso para cada matriz. Sobre estas formas se prueba la hipótesis planteada. La fase inicial comprende la segmentación de imágenes para crear una base de datos de todos los sistemas nubosos observados durante el fenómeno, junto con las características propuestas. Se procesaron 3419 objetos de sistemas nubosos cuyas máscaras binarias contienen más de cinco píxeles (umbral mínimo de área = 5 px) a la resolución considerada (2.36 km por píxel). Para evaluar robustez se realizaron pruebas cruzadas con diferentes tamaños de ventana de píxeles (5, 10, 20, 50 px) y distintos umbrales de lluvia (30–70 mm/h); véase el Apéndice A.

Como se observa en la Figura **??**, los valores de precipitación iguales o superiores a 50 mm/h se ubican en categorías de peligro alto y muy alto, asociadas con mayores profundidades de flujo, velocidades más severas y daños esperados considerablemente más importantes. En particular, el intervalo $50 \leq R < 70$ mm/h marca una transición hacia escenarios con afectaciones estructurales relevantes, mientras que para valores aún mayores el daño esperado se intensifica hasta condiciones extremas. Por esta razón, en la presente investigación se consideran umbrales de lluvia fuerte superiores a 50 mm/h, ya que estos permiten centrar el análisis en las regiones nubosas de mayor

interés hidrometeorológico, es decir, aquellas con potencial de generar impactos significativos y que, por tanto, resultan más relevantes para estudiar la relación entre la geometría del sistema nuboso y la intensidad de precipitación.

Figura 4.1
Clasificación de escalas y factores de riesgo de daños sugerida para la región de América Latina y el Caribe (?)

Table C.1. Damage hazards scales and factors classification suggested for LAC region [74,82,73,28,15,29,83,84,75,23,9,26]

Damage state-factor range [Damage or risk]	Rain rate R (mm h^{-1}) [Rainfall height hp] (mm $24h^{-1}$)	Hazard flow-velocity (m s^{-1}) [Landslide] velocity	Hazard flow depth y (m) [flood duration]	Jointly flow depth y (m) and flow velocity v (m s^{-1})	Safe for … [Expected damage]
Slight-very slow (0-1) [1%]	< 5 < 5	< 0.5 [16mm/year]	< 0.2 [< 6 h]	$y < 0.5$ & $v < 15$	All save [Not damage]
Light-low-slow (1-10) [5%]	$5 \leq R < 20$ $5 \leq hp_{24} < 20$	$0.5 \leq v < 1$ [1.6m/year]	$0.2 \leq y < 0.5$ [6 – 12 h]	$0.5 \leq y < 1$ & $v < 3$	Cars and able bodied adults [Water and sediment-laden water ingresses building's main floor or basement]
Moderate-medium (10-30) [20%]	$20 \leq R < 30$ $20 \leq hp_{24} < 50$	$1 \leq v < 2$ [13m/month]	$0.5 \leq y < 0.8$ [12 – 18 h]	$1 \leq y < 1.5$ & $v < 2$	Heavy vehicles and wading for adults [Lost related to wet furniture and some supporting elements damaged]
Heavy-high-fast (30-60) [45%]	$30 \leq R < 50$ $50 \leq hp_{24} < 70$	$2 \leq v < 3$ [1.8m/hour]	$0.8 \leq y < 1$ [18 – 24 h]	$1.5 \leq y < 2$ & $v < 1.5$	Light constructions [Furniture wet, broken windows and doors are reported]
Major-very high-very fast (60-100) [80%]	$50 \leq R < 70$ $70 \leq hp_{24} < 150$	$3 \leq v < 4$ [3m/min]	$1 \leq y < 1.5$ [24 – 48 h]	$2 \leq y < 3$ & $v < 3$	Heavy constructions [Everything get wet and damage to crucial building-supporting piles and walls]
Destroyed-extreme-extremely fast (100) [100%]	$R \geq 70$ $hp_{24} \geq 150$	> 4 [5m/s]	$y > 1.5$ [> 48 h]	$y > 3$ & $v > 3$	Nothing [Structure is completely damaged or destroyed]

4.6. Hidroestimador

El Hidroestimador (HE) es un enfoque operativo que estima la tasa de lluvia (mm/h) a partir de imágenes infrarrojas geoestacionarias (canal 4). Su propósito principal es proporcionar campos de precipitación casi en tiempo real sobre regiones con cobertura limitada de radar, facilitando el *nowcasting* y el monitoreo de sistemas convectivos como los ciclones tropicales. La entrada consiste en la temperatura/brillo del tope nuboso por píxel obtenida del canal IR-4, y la salida es la tasa de lluvia por píxel y, opcionalmente, promedios horarios por píxel (**?**).

Las propuestas se formularon con base en tres variables objetivo: la intensidad media de lluvia, la moda y el valor máximo. La moda corresponde al valor más frecuente registrado entre el conjunto de píxeles que constituyen la forma bajo estudio, y el máximo corresponde a la mayor intensidad de lluvia dentro de la forma del sistema nuboso.

4.7. Análisis de Componentes Principales

El Análisis de Componentes Principales (ACP) es una técnica estadística multivariada que transforma un conjunto de variables posiblemente correlacionadas en un nuevo sistema de variables lineales no correlacionadas, las componentes principales. Estas se ordenan de modo que la primera explica la mayor proporción posible de la variabilidad total, la segunda explica la mayor parte de la variabilidad restante bajo la restricción de ser ortogonal a la primera, y así sucesivamente (**??**).

Geométricamente, el ACP puede verse como una rotación del sistema de coordenadas hacia las direcciones de mayor dispersión de la nube de datos. Por eso resulta útil cuando se trabaja con descriptores de forma, que suelen presentar redundancia o colinealidad: el ACP sintetiza la información de varios descriptores geométricos en pocas componentes, y facilita tanto visualizar como interpretar los patrones dominantes del conjunto de datos.

Aquí el ACP se usa con dos propósitos: reducir la dimensionalidad del problema sin perder la estructura esencial de la variabilidad geométrica de las regiones nubosas, y servir de base para analizar la relación entre los descriptores de forma y las variables de precipitación. Los círculos de correlación, en particular, permiten ver qué descriptores se agrupan entre sí, cuáles aportan información parecida y cuáles se relacionan más de cerca con la intensidad de lluvia.

4.8. Agrupamiento *k-means*

El algoritmo *k-means* es un método de clasificación no supervisada que busca particionar un conjunto de observaciones en k grupos, de modo que los elementos de un mismo grupo sean lo más parecidos posible entre sí y lo más distintos posible de los de otros grupos (**??**). Para ello minimiza la suma de cuadrados intra-grupo, es decir, la variabilidad de las observaciones respecto al centroide de su grupo.

El procedimiento consiste en fijar un número k de grupos, asignar centroides iniciales y repetir dos pasos: asignar cada observación al centroide más cercano, y recalcular los centroides como el promedio de las observaciones que quedaron en cada grupo. Se detiene cuando las asignaciones dejan de cambiar o la reducción de la variabilidad intra-grupo ya es despreciable. Por su naturaleza iterativa, el método puede depender de la inicialización y de la escala de las variables, por lo que suele aplicarse sobre datos normalizados.

Aquí se usa después del ACP, para identificar agrupamientos naturales entre las regiones nubosas a partir de sus descriptores geométricos y sus variables de precipitación. La combinación tiene sentido porque las componentes principales representan

los datos en un espacio de menor dimensión y menor redundancia, mientras que el agrupamiento distingue categorías de nubes con comportamiento morfológico parecido: juntas permiten explorar si hay patrones geométricos recurrentes y si se relacionan con distintos niveles de intensidad de lluvia.

Capítulo 5

Geometría de las variables

Las mediciones presentadas a continuación se consideraron porque dependen de elementos básicos de una forma bidimensional: área, perímetro, diámetro y radio. Los descriptores geométricos muestran colinealidad entre sí (por ejemplo, perímetro–diámetro, redondez y compacidad). Para sintetizar la información y preservar interpretabilidad física se aplicó ACP sobre la matriz de correlación. En la selección de componentes se priorizaron aquellas que alcanzan al menos 80 % de varianza acumulada. También se emplearon círculos de correlación para identificar qué grupos de descriptores se asocian con las métricas de lluvia (media, moda y máximo). Este procedimiento produce ejes ortogonales estables que resumen la variabilidad dominante de la forma y facilitan su relación con la intensidad de precipitación.

Tabla 5.1
Variables geométricas y pluviométricas utilizadas en el análisis.

Parámetro	Descripción
Area	Área de la forma.
ConvexArea	Área de la envolvente convexa.
Perimeter	Perímetro de la forma.
radio_max	Radio máximo de la región.
radio_min	Radio mínimo de la región.
Rain	Intensidad media de lluvia asociada.
Mode	Valor de lluvia más frecuente en la región analizada.
Max	Valor máximo de intensidad de lluvia en la región.
Median	Mediana de la intensidad de lluvia.
Dstandard	Desviación estándar de los valores de lluvia.
Variance	Varianza de la intensidad de lluvia en la región.

5.1. Escala y cálculo de descriptores

Los descriptores de forma (FF, RF, RR, CAC y RSG) se calcularon en unidades de píxel sobre máscaras binarias. El área A corresponde al número de píxeles del objeto y el perímetro P al número de píxeles de frontera (conectividad 8). Los diámetros D, d y $d_{\text{máx}}$ se expresan en píxeles. Con estas unidades consistentes, los descriptores son adimensionales e invariantes a escala dentro de la misma rejilla.

5.2. Descriptores clásicos

5.2.1. Comparación entre área y perímetro

La medida de circularidad más utilizada corresponde a la propuesta en (**?**). También conocida como factor de forma o índice de circularidad, se calcula mediante:

$$FF = \frac{A}{A_p} = \frac{4\pi A}{P^2}, \tag{5.1}$$

donde A es el área del objeto, A_p es el área del círculo con el mismo perímetro que el objeto y P es el perímetro del objeto.

5.2.2. Comparación entre área y diámetro

La siguiente medida, propuesta en (**?**), está dada por:

$$RF = \frac{A}{A_{\text{máx}}} = \frac{4A}{\pi d_{\text{máx}}^2}, \tag{5.2}$$

donde A es el área del objeto, $A_{\text{máx}}$ es el área del círculo cuyo diámetro es el máximo del objeto y $d_{\text{máx}}$ es la mayor distancia entre dos puntos del contorno.

5.2.3. Relación entre radios

Una medida de circularidad basada en la relación entre dos radios fue propuesta en (**?**) como:

$$RR = \frac{r_{\text{mín}}}{r_{\text{máx}}}, \tag{5.3}$$

donde $r_{\text{mín}}$ es el radio mínimo medido desde el centroide al contorno y $r_{\text{máx}}$ es el radio máximo.

5.2.4. Medida de redondez

Otra medida asociada a la relación entre radios, también basada en (**?**), se define como:

$$MR = \frac{1}{n}\sum_{j=1}^{n}\frac{\overline{r_b}}{|r_j - \overline{r_b}| + \overline{r_b}}, \tag{5.4}$$

donde $\overline{r_b}$ es el promedio de los radios medidos desde el centroide al borde y r_j es el radio asociado al píxel j del contorno.

5.2.5. Medición de convexidad

Una forma de describir la forma de un objeto es mediante su convexidad. Una manera de medirla es mediante la razón entre el área del objeto y el área de su envolvente convexa. Algunas variantes para polígonos pueden encontrarse en (**?**). La convexidad se define por:

$$CA = \frac{A(K)}{A_H(K)}, \tag{5.5}$$

donde K denota la forma, $A(K)$ su área y $A_H(K)$ el área de su envolvente convexa.

5.3. Descriptores propuestos

A continuación se presentan dos propuestas para caracterizar la forma de nubes. Un cuerpo de ancho constante es aquel que presenta la misma anchura en todas las direcciones. La anchura de un objeto en una dirección dada es la distancia entre un par de rectas paralelas tangentes al objeto. Para una anchura fija, el cuerpo de ancho constante con mayor área es el círculo, de modo que estas relaciones también ayudan a medir la circularidad de un objeto.

Lema 5.1. *Sea K una curva convexa y cerrada en el plano. Si para todo punto $p \in \partial K$ la cuerda más grande que pasa por p tiene siempre la misma longitud, entonces K es de ancho constante.*

Esta proposición caracteriza cuerpos de ancho constante a partir de la medición del ancho desde cada punto del borde de la figura. Un caso que satisface esta propiedad es el círculo, pues todos sus diámetros coinciden. Sin embargo, existen figuras distintas del círculo que también la cumplen. Con base en esta idea se define el descriptor siguiente.

Lema 5.2. *Sean p_i y p_j dos puntos del contorno de una forma A, con $i, j \in I$, donde I es el conjunto de todos los puntos del borde. Sea $d_i = \max\{|p_i - p_k| : k \in I\}$, y definamos:*

$$D = \max\{d_i : i \in I\}, \qquad d = \min\{d_i : i \in I\}.$$

Entonces puede definirse una medida de circularidad basada en ancho constante por medio de la razón entre ambos valores extremos.

La medida propuesta es:

$$CAC = \frac{d}{D}, \tag{5.6}$$

donde d corresponde al mínimo de las mayores distancias desde los puntos del contorno y D al máximo. Si $CAC = 1$, el objeto es de ancho constante; si es cercano a 0, el objeto degenera hacia una configuración altamente no uniforme.

Relación entre perímetro y diámetro

En **?** se establece la siguiente propiedad para curvas simples cerradas.

Lema 5.3. *Toda curva convexa y cerrada en el plano, de longitud L y diámetro D, satisface $L \leq \pi D$. La igualdad se alcanza si y solo si la curva tiene ancho constante D.*

A partir de esta desigualdad se define:

$$RSG = \frac{P}{\pi D}, \tag{5.7}$$

donde P es el perímetro de la forma y D su diámetro. Los dos descriptores propuestos permiten medir qué tan cercana es una forma a un objeto de ancho constante.

Tabla 5.2
Ecuaciones de los parámetros geométricos utilizados.

Factor	Ecuación	Descripción
MR	$MR = \frac{1}{n}\sum_{j=1}^{n} \frac{\overline{r_b}}{\lvert r_j - \overline{r_b}\rvert + \overline{r_b}}$	Redondez media.
RR	$RR = \frac{r_{\text{mín}}}{r_{\text{máx}}}$	Medida de circularidad basada en radios.
CAC	$CAC = \frac{d}{D}$	Medida de circularidad basada en ancho y diámetro.
RSG	$RSG = \frac{P}{\pi D}$	Razón entre perímetro y diámetro.
FF	$FF = \frac{4\pi A}{P^2}$	Factor de forma.
RF	$RF = \frac{4A}{\pi d_{\text{máx}}^2}$	Factor de redondez.
CA	$CA = \frac{A(K)}{A_H(K)}$	Medida de convexidad basada en área.

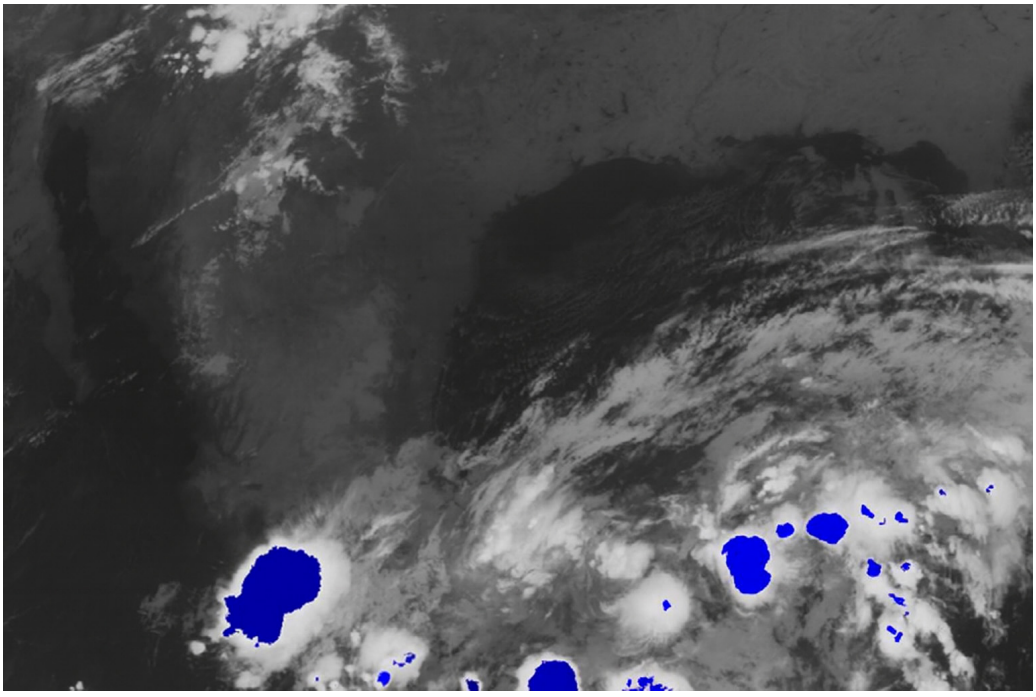
Desde el punto de vista geométrico, una medida basada en ancho constante puede considerarse más general que una basada únicamente en circularidad. En efecto, el círculo posee la propiedad de tener el mismo ancho en todas las direcciones, pero no

es la única figura que la satisface; existen otras curvas de ancho constante, como el triángulo de Reuleaux. En este sentido, una medida construida a partir de la cercanía a cuerpos de ancho constante no se restringe al caso particular de la circunferencia, sino que abarca una familia más amplia de formas convexas. Además, mientras que el teorema de Rosenthal–Szasz establece que la igualdad en la relación $L \leq \pi D$ se alcanza precisamente para curvas de ancho constante, el teorema de Bieberbach muestra que la igualdad en $4A \leq \pi D^2$ caracteriza únicamente a la circunferencia. Por ello, un descriptor como CAC o RSG, fundamentado en propiedades de ancho constante, permite una lectura geométrica más amplia: no mide solamente qué tan circular es una forma, sino qué tan próxima se encuentra a la clase general de los cuerpos de ancho constante, de la cual el círculo constituye un caso particular y extremal.

5.4. Formas dentro del sistema nuboso

La Figura **??** presenta una imagen satelital digital capturada por el satélite GOES-13, en la que se ilustran los sistemas nubosos más intensos generados a partir del procesamiento de la información. Estos sistemas fueron superpuestos sobre la imagen y corresponden a regiones caracterizadas por lluvia extrema.

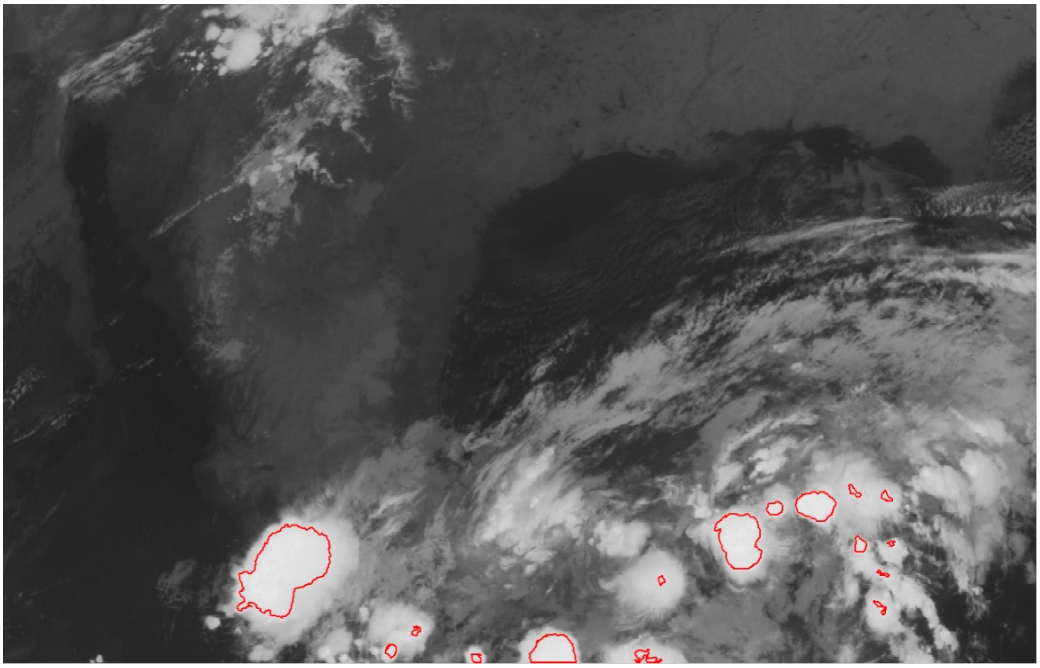
Figura 5.1
Áreas de lluvia extrema ($\geq$ 50 mm/h) en el huracán Patricia, 19 de octubre de 2015, 09:15 UTC.



La Figura **??** muestra una imagen satelital en escala de grises, en la cual se observan

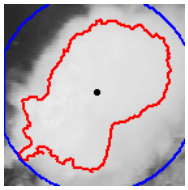
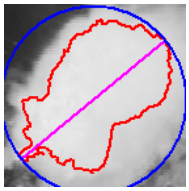
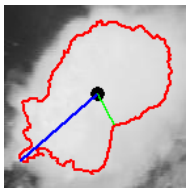
formaciones nubosas de distinta densidad a lo largo de la escena. Los contornos rojos delimitan regiones con mayor intensidad de lluvia, es decir, zonas donde la precipitación pronosticada es particularmente alta.

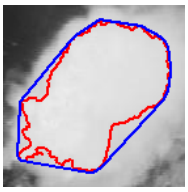
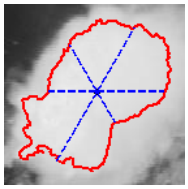
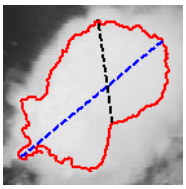
Figura 5.2
Segmentación de regiones con mayor intensidad de lluvia. Los contornos rojos delimitan las áreas identificadas por el algoritmo como regiones con precipitación más intensa.

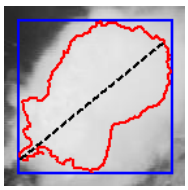


En la Tabla **??** se comparan distintos descriptores de forma (FF, RF, RR, CA, MR, CAC y RSG) aplicados a recortes de nubes obtenidos a partir de una imagen satelital digital. Cada fila corresponde a un descriptor específico e incluye la imagen de referencia, una descripción geométrica y el valor del indicador.

Tabla 5.3
Descriptor de forma.

Factor	Figura	Descripción	Valor
FF		Área del objeto: el área del círculo con perímetro 18,654.67 es equivalente a 8204. El indicador se obtiene dividiendo el área del objeto entre el área del círculo con el mismo perímetro, lo que permite valorar el grado de circularidad de la nube en condiciones de lluvia intensa. La imagen muestra un segmento de una imagen satelital digital con la superposición correspondiente.	0.44
RF		En esta imagen, la nube está delineada en rojo y contenida dentro de un círculo azul, cuyo diámetro corresponde a la distancia máxima entre dos puntos del contorno (línea magenta). Para obtener el indicador, se compara el área del círculo delimitado (16,180.77) con la del objeto mismo (8204). Esta razón cuantifica la proporción del círculo definido por su mayor extensión que es ocupada por el objeto y proporciona una métrica de su compacidad o dispersión respecto a la circunferencia que lo contiene.	0.51
RR		La imagen muestra un recorte de nube resaltado en rojo, junto con un punto negro en el centro que representa el centroide del objeto. Las líneas de color indican las distancias mínima y máxima desde el centroide hasta el contorno, con valores de 26.97 y 77.54, respectivamente. El descriptor se obtiene calculando la razón entre el radio menor y el radio mayor, proporcionando así una medida simple de la forma de la nube al comparar su extensión mínima y máxima desde el centro.	0.35

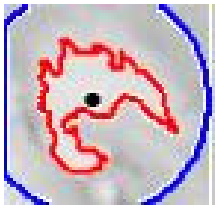
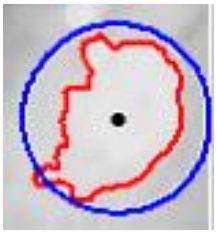
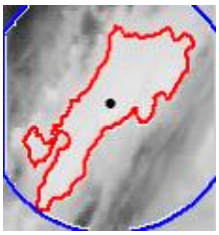
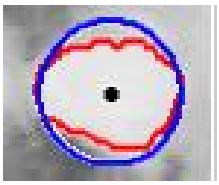
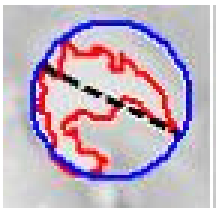
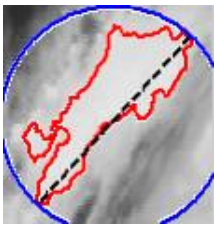
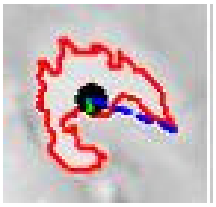
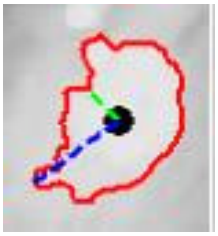
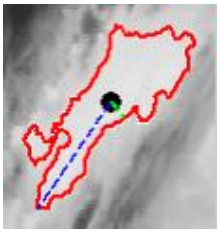
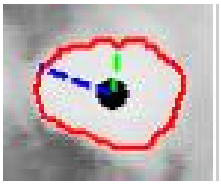
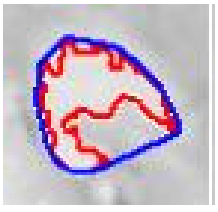
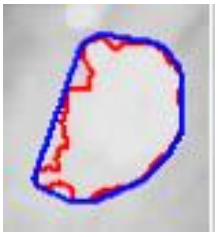
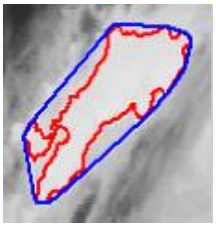
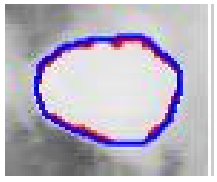
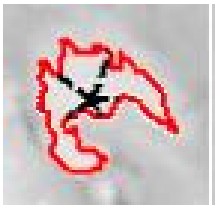
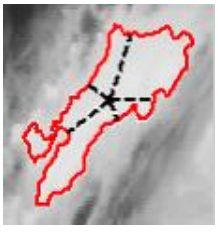
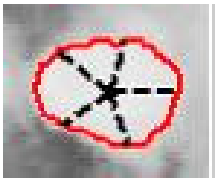
Factor	Figura	Descripción	Valor
CA		La imagen ilustra el contorno de la nube en rojo, mientras que la envolvente convexa, delineada en azul, representa el polígono convexo más pequeño capaz de encerrar completamente la nube. El área de la nube (8204) se compara con la del polígono convexo (9590) para definir un indicador que mide la compacidad del objeto. Cuanto más cercana sea el área de la nube a la de su envolvente convexa, mayor será la compacidad de la forma.	0.86
MR		La imagen muestra la nube delineada en rojo, con múltiples líneas azules que se extienden desde un punto central hasta el borde y miden distintos radios. A partir de estos valores se obtiene un promedio de 53.18. Este promedio se utiliza para comparar cada radio con el valor medio y así evaluar el grado en que la forma de la nube se aproxima a una distribución radial uniforme. El descriptor resultante ofrece una referencia de la regularidad o simetría del contorno respecto al centro.	0.86
CAC		La imagen presenta un contorno rojo que delimita el área de máxima intensidad de lluvia. Sobre este contorno se han trazado dos líneas punteadas: la azul representa la mayor distancia entre dos puntos del borde (143.53), mientras que la negra indica la distancia mínima dentro del conjunto de máximas distancias posibles (80.75). El descriptor se define como la razón entre esa distancia mínima y la máxima, proporcionando una medida de la uniformidad o elongación de la forma de la nube.	0.56

Factor	Figura	Descripción	Valor
RSG		La imagen muestra un recorte de nube con la región de máxima intensidad de lluvia delineada en rojo, así como una línea negra punteada que denota la máxima distancia entre dos puntos del contorno, cuyo valor es 143.53, mientras que el perímetro total es 484. El descriptor propuesto se obtiene al relacionar el perímetro con la máxima distancia y la constante π, permitiendo una medición simple de la forma del objeto usando únicamente dos parámetros.	0.96

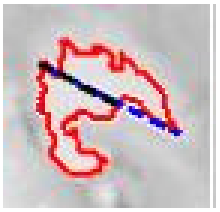
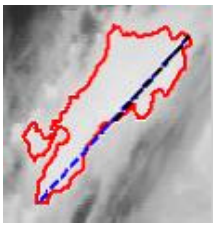
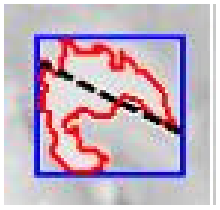
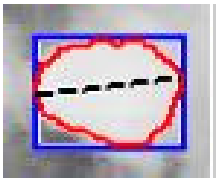
La Tabla **??** presenta una comparación visual y numérica de la forma en que cada descriptor caracteriza distintas morfologías nubosas presentes en la imagen satelital.

Como se observa en la Tabla **??**, los descriptores propuestos CAC y RSG no cuantifican exactamente el mismo aspecto de la geometría, sino propiedades complementarias de la forma. En el caso de CAC, los valores reportados (0,54, 0,60, 0,50 y 0,69) indican distintos grados de uniformidad en el ancho de las regiones nubosas analizadas. En particular, la tercera imagen, con $CAC = 0{,}50$, es la que presenta la mayor variación de ancho y, por tanto, la menor cercanía a una figura de ancho constante, mientras que la cuarta, con $CAC = 0{,}69$, es la que muestra la mayor homogeneidad geométrica dentro del conjunto. Por otro lado, el descriptor RSG toma los valores 1,48, 1,01, 1,11 y 0,96, lo cual permite distinguir la complejidad del contorno en relación con la extensión máxima de cada objeto. Desde esta perspectiva, la primera imagen, con $RSG = 1{,}48$, corresponde a la forma más irregular del grupo, pues su perímetro es relativamente grande respecto a su diámetro, mientras que la cuarta, con $RSG = 0{,}96$, representa la forma más equilibrada en términos globales. En conjunto, estos resultados muestran que CAC resulta especialmente útil para evaluar la uniformidad del ancho, mientras que RSG describe de mejor manera la relación entre borde y extensión máxima. Así, ambos descriptores se complementan y permiten una caracterización geométrica más rica de las nubes analizadas que la que se obtendría empleando una sola medida.

Tabla 5.4
Factores que caracterizan la morfología de las nubes.

Factor de Forma	**Ejemplos de sistemas de nubes con sus valores de factor de forma**			
FF				
	0.18	0.53	0.20	0.73
RF				
	0.40	0.54	0.25	0.68
RR				
	0.13	0.41	0.15	0.58
CA				
	0.57	0.85	0.66	0.93
MR				
	0.82	0.86	0.77	0.90

Factores que caracterizan la morfología de las nubes.

Factor de Forma	**Ejemplos de sistemas de nubes con sus valores de factor de forma**			
CAC				
	0.54	0.60	0.50	0.69
RSG				
	1.48	1.01	1.11	0.96

Como se ilustra bajo cada imagen, se asigna un valor numérico al descriptor para esa nube particular. Estos valores reflejan distintos aspectos de la geometría de la nube, tales como compacidad, elongación, circularidad u otras propiedades morfológicas. En consecuencia, la Tabla **??** ofrece una comparación visual, mediante imágenes, y numérica, mediante valores, de la forma en que cada descriptor caracteriza la morfología de las nubes en la imagen satelital.

Durante el estudio de la evolución del huracán entre el 22 y el 24 de octubre de 2015 se realizó un análisis basado en imágenes del satélite GOES-13. Para el análisis detallado se empleó el algoritmo `AnalysisRainGOES13`, cuyo objetivo principal es procesar datos de intensidad de lluvia obtenidos mediante segmentación de imágenes satelitales. El procesamiento incluyó la aplicación de ACP y la clasificación usando el algoritmo k-means. Los datos procesados se encuentran en un conjunto de archivos CSV correspondientes a imágenes de 817×1280 píxeles. En el Apéndice B se presenta una descripción del pseudocódigo implementado.

Capítulo 6

Resultados

A continuación se presentan los resultados obtenidos al aplicar ACP a la base de datos que contiene los diferentes descriptores. En este análisis inicial, la variable objetivo es la intensidad media de lluvia. La visualización bidimensional del espacio del ACP mostró grupos bien diferenciados, lo que sugiere que la segmentación realizada es razonable. A pesar de utilizar el método del codo para la elección del número de grupos también se considero la parsimonia como parte de la experiencia en el campo se adopta (**?**), se adopta $k = 4$.

Figura 6.1
Visualización bidimensional de k-means en el espacio del ACP.

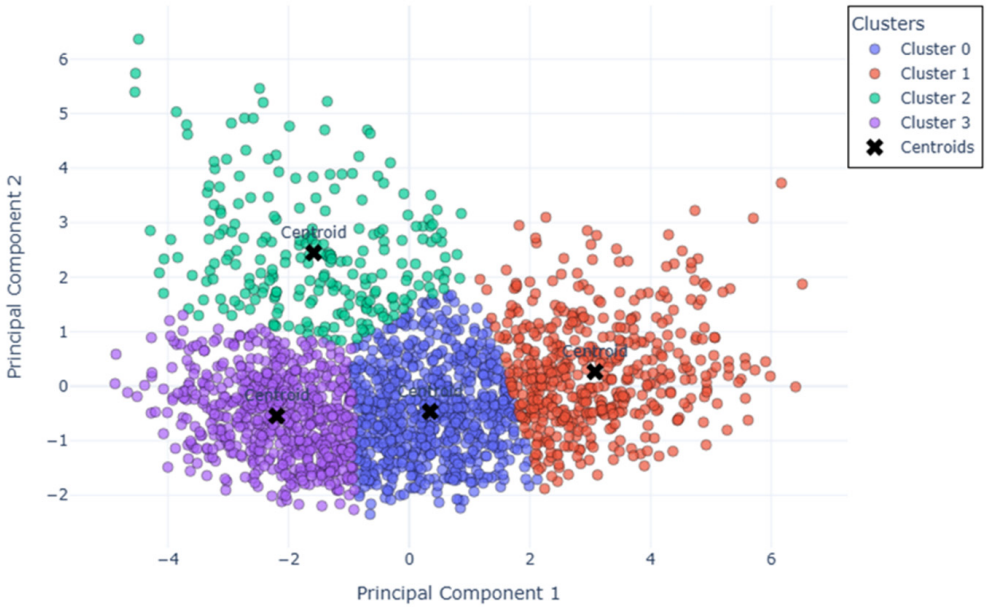


Tabla 6.1
Proyecciones en dos componentes.

Factor	ACP-1	ACP-2
RR	0.41823995	0.14476456
CAC	0.36728841	0.31005496
RSG	−0,28502252	0.57335478
FF	0.39736106	−0,24989648
RF	0.38652358	0.28018747
MR	0.35730487	0.31767739
CA	0.38685201	−0,12561905
Rain	−0,15594614	0.54453752

Tabla 6.2
Proyecciones en tres componentes principales.

Factor	PC1	PC2	PC3
RR	0.41823995	0.14476456	−0,02901164
CAC	0.36728841	0.31005496	−0,18264375
RSG	−0,28502252	0.57335478	−0,24402476
FF	0.39736106	−0,24989648	0.21561371
RF	0.38652358	0.28018747	−0,14973593
MR	0.35730487	0.31767739	−0,20501669
CA	0.38685201	−0,12561905	0.45230733
Rain	−0,15594614	0.54453752	0.76858807

La incorporación de una tercera componente permitió mejorar la separación entre grupos, sugiriendo un agrupamiento satisfactorio mediante k-means.

Figura 6.2
Visualización tridimensional de k-means en el espacio del ACP.

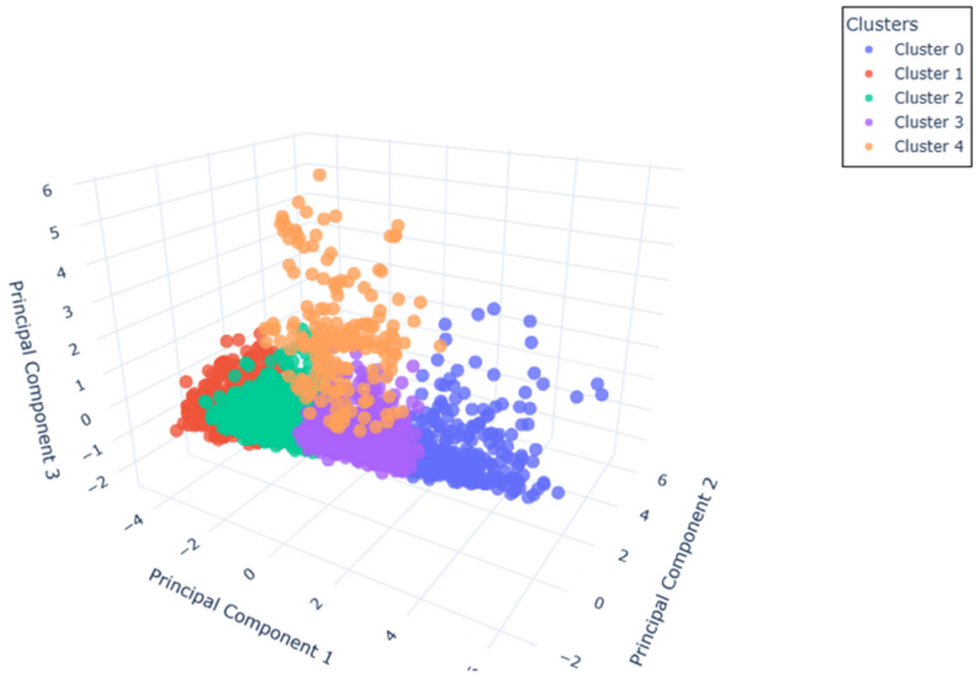


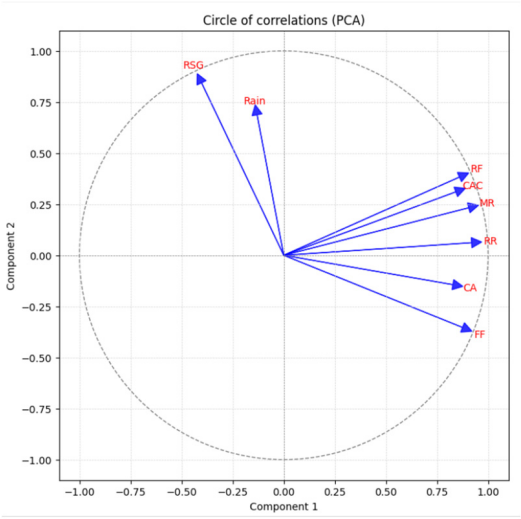
Tabla 6.3
Resumen comparativo de los análisis ACP para cada variable objetivo.

Variable objetivo	Componentes	% de varianza explicada
Intensidad de lluvia	2	74 %
Moda de la intensidad de lluvia	2	71 %
Valor máximo de la intensidad de lluvia	2	75 %
Intensidad de lluvia	3	81 %
Moda de la intensidad de lluvia	3	80 %
Valor máximo de la intensidad de lluvia	3	83 %

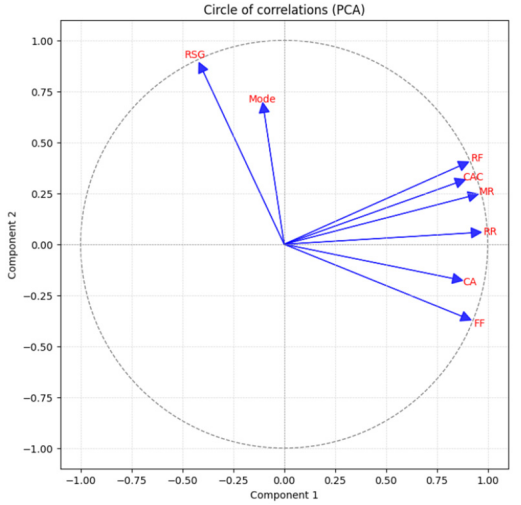
Los círculos de correlación sugieren una fuerte correlación entre la variable RSG y las componentes principales. Además, el ángulo entre las tres variables objetivo y RSG es pequeño, lo que indica una asociación alta. De esta forma, RSG puede utilizarse como predictor para estimar la variable objetivo.

Tras la evaluación de los factores geométricos se determinó que solo el descriptor RSG mostró una asociación lineal positiva y estadísticamente significativa con las tres métricas de intensidad de lluvia (máximo, media y moda). Los valores de R^2 fueron 0.34, 0.53 y 0.40, respectivamente.

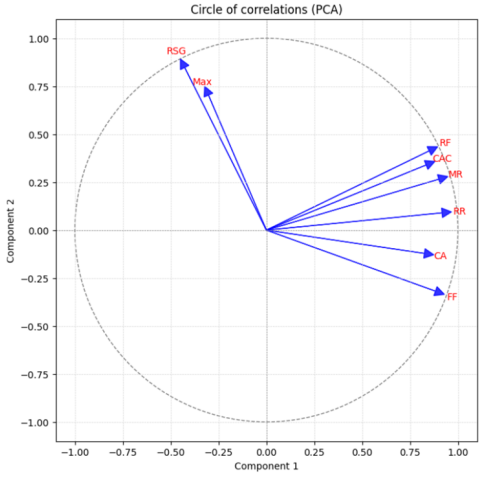
Figura 6.3
Círculos de correlación correspondientes a la intensidad media, la moda y el máximo de precipitación.



(**a**)



(**b**)



(**c**)

Los círculos de correlación de la Figura **??** son una pieza clave del análisis: cada flecha representa la proyección de una variable original sobre el plano de las dos primeras componentes principales. La dirección del vector indica el tipo de relación con las demás variables, y su longitud, qué tan bien queda representada en ese plano. Variables con vectores cercanos están correlacionadas positivamente, vectores opuestos indican correlación negativa, y vectores casi ortogonales, una asociación lineal débil.

En las tres gráficas aparece el mismo patrón. Los descriptores clásicos –FF, RF, RR, MR, CA y CAC– se agrupan en el semiplano derecho, asociados sobre todo a la primera componente: aunque se definen de maneras distintas, en la práctica miden rasgos morfológicos emparentados (compacidad, redondez, convexidad, uniformidad radial) y forman un grupo altamente correlacionado entre sí. RSG, en cambio, aparece sistemáticamente separado, en el semiplano izquierdo superior, junto con las tres variables de precipitación (*Rain*, *Mode*, *Max*). Esa cercanía angular es la evidencia visual de que RSG aporta una dimensión geométrica distinta de los descriptores clásicos y se asocia más de cerca con la lluvia.

La alineación es más fuerte con *Rain* y con *Max* –las flechas apuntan casi en la misma dirección que RSG– y algo menos exacta con *Mode*, aunque sigue siendo la más cercana entre todos los descriptores. Que RSG se acerque tanto al máximo de precipitación importa en particular, porque los máximos de lluvia suelen asociarse con los eventos de mayor impacto –inundaciones repentinas, daños severos a la infraestructura– ; la relación entre perímetro y diámetro parece capturar algo más que una regularidad formal abstracta, y podría estar ligada a la concentración espacial de la lluvia intensa.

Esta disposición también dice algo sobre las componentes mismas. La primera componente principal actúa como un eje que contrasta dos familias: los descriptores clásicos de circularidad, redondez y convexidad por un lado, y RSG junto con las variables de precipitación por el otro; es decir, separa la compacidad tradicional de una medida que compara directamente el borde con la extensión máxima del objeto. La segunda componente distingue matices más finos –separa ligeramente FF y CA del resto de los clásicos–, pero *Rain*, *Mode* y *Max* se mantienen juntas y cercanas a RSG en ambos ejes.

Esto es coherente con la naturaleza del descriptor: mientras los clásicos comparan área, radios o convexidad contra un modelo ideal cercano al círculo, RSG relaciona perímetro y diámetro, y por eso capta la tensión entre la complejidad del borde y la extensión global del objeto. El círculo es solo un caso particular de la familia de formas de ancho constante, y un descriptor que no se restringe a medir cercanía a la circunferencia se adapta mejor a morfologías nubosas reales, casi siempre irregulares, elongadas y solo parcialmente compactas. El ACP hace visible esta ventaja: los descriptores clásicos se mantienen muy correlacionados entre sí, mientras que RSG se

separa del grupo y se acerca de forma sistemática a las variables de precipitación.

En conjunto, la Figura **??** sostiene una conclusión sólida: *RSG* es el descriptor con la relación más consistente con las tres variables de precipitación, y esa consistencia se repite en los tres círculos de correlación, no en uno solo. Es evidencia central a favor de la hipótesis de trabajo: la geometría del sistema nuboso, bien descrita, sí se asocia con la magnitud y distribución de la precipitación –y de entre los descriptores evaluados, *RSG* es el más cercano, el más estable y el más interpretable frente a la lluvia.

Tabla 6.4
Valores de R^2 para sistemas nubosos con tasas de lluvia mayores a 50 mm/h y objetos mayores de 20 píxeles.

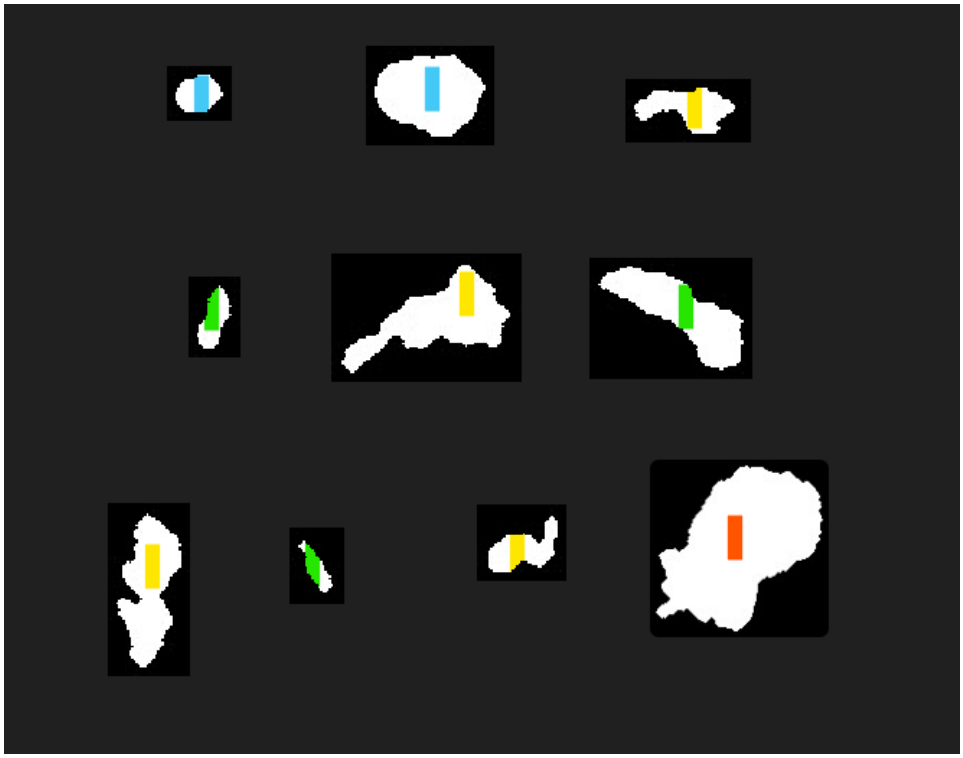
Conjunto de datos	Predictor	R^2
Max	RR	0.00
Max	CAC	0.01
Max	RSG	0.34
Max	FF	0.10
Max	RF	0.03
Max	MR	0.00
Max	CA	0.04
Mode	RR	0.01
Mode	CAC	0.01
Mode	RSG	0.40
Mode	FF	0.13
Mode	RF	0.02
Mode	MR	0.00
Mode	CA	0.04
Rain (media)	RR	0.05
Rain (media)	CAC	0.00
Rain (media)	RSG	0.53
Rain (media)	FF	0.24
Rain (media)	RF	0.00
Rain (media)	MR	0.01
Rain (media)	CA	0.11

6.1. Validación cualitativa de la clasificación

Además del análisis cuantitativo con descriptores geométricos, ACP y clasificación, conviene revisar los resultados también de forma cualitativa: ver si los grupos que arroja el algoritmo corresponden a patrones morfológicos distinguibles a simple vista, y no solo a una separación estadística. Una validación así no se queda en las métricas: pide verificar si los objetos de una misma categoría comparten semejanzas apreciables en su contorno, compacidad, elongación y organización espacial.

En el material gráfico del análisis final, las nubes agrupadas en una misma categoría comparten rasgos visuales claros. Algunas categorías concentran formas compactas, cercanas a estructuras de ancho casi constante; otras reúnen objetos más alargados, fragmentados o de bordes menos uniformes (Figura **??**). Que esa homogeneidad intraclase no sea casual, sino resultado directo de clasificar con descriptores geométricos, es evidencia de que la forma sí está capturando información estructural del sistema nuboso.

Figura 6.4
Resultado visual de la clasificación. La similitud de las nubes dentro de cada categoría sugiere coherencia morfológica intraclase.



Esta lectura complementa al análisis estadístico, no lo sustituye: los resultados cuantitativos dicen qué descriptores se relacionan mejor con la precipitación, y la inspección visual confirma que esa relación también se ve en la organización morfológica

de las nubes. Cuando objetos con valores geométricos parecidos terminan agrupados y además se ven parecidos, la clasificación tiene sentido físico y no solo numérico. Con esto cierra el capítulo de resultados: la clasificación produce categorías geométricamente coherentes, la forma segmentada y los descriptores calculados convergen en una misma lectura del fenómeno, y la morfología de los sistemas nubosos contiene información útil para caracterizar y clasificar sistemas nubosos en relación con la intensidad de lluvia.

Capítulo 7

Discusión

Desde una perspectiva física, la configuración de un ciclón tropical refleja la interacción dinámica entre fuerzas centrífugas, gradientes de presión y convección latente. Una estructura anular, por ejemplo, se ha vinculado con un régimen de precipitación más estable y eficiente, con la lluvia concentrada en un anillo de pared del ojo (**?**); estructuras más alargadas y con múltiples bandas, en cambio, sugieren una convección menos organizada y más dispersa (**?**). Estas configuraciones impactan directamente la distribución de la lluvia, en intensidad y en extensión geográfica. El presente estudio muestra que la intensidad de lluvia guarda relación con la configuración geométrica del sistema precipitante, y agrega un componente propio a las geometrías de Dvorak.

RSG surge como un predictor fuerte de la intensidad de lluvia. No se observa, en cambio, una correlación equivalente con los descriptores clásicos, lo que indica que RSG capta rasgos de organización que esas variables más tradicionales no representan. Esto sugiere que puede ser útil en modelos de alerta temprana, en particular para anticipar eventos de precipitación extrema.

El enfoque convencional de la técnica de Dvorak se ha centrado en la intensidad del viento, pero la disponibilidad de datos satelitales de alta resolución ha permitido reinterpretarlo desde una perspectiva hidrológica. **?** y **?** muestran que los avances en percepción remota pueden combinarse con los patrones de Dvorak para deducir tasas de precipitación a partir de características geométricas, como el radio de simetría, la definición del ojo o el ancho de las bandas convectivas.

7.1. Desarrollos recientes y perspectivas futuras

El aprendizaje profundo y el análisis automatizado de imágenes satelitales han abierto una línea de investigación paralela a la de esta tesis. **?** propusieron un modelo de redes neuronales para estimar la intensidad de ciclones tropicales, con resultados que superan en precisión a la metodología tradicional de Dvorak. Más cerca del pro-

blema que aquí se estudia, **?** usaron secuencias de imágenes satelitales y aprendizaje profundo específicamente para pronosticar la precipitación de ciclones tropicales, no solo su intensidad de viento. Que ambas líneas –geométrica y de aprendizaje profundo– converjan hacia la precipitación como variable de interés refuerza la pertinencia de este trabajo: la técnica de Dvorak sigue siendo útil, pero su lectura geométrica admite tanto extensiones interpretables como el descriptor RSG aquí propuesto, como extensiones basadas en modelos más complejos, y ambas pueden complementarse en flujos operativos futuros.

Capítulo 8

Conclusiones

La técnica de Dvorak ha sido la metodología de referencia para estimar la intensidad de ciclones tropicales desde su desarrollo en la década de 1970 (**?**). Es confiable y sigue en uso extensivo, pero sus límites para valorar con precisión tormentas extremas han motivado la búsqueda de metodologías nuevas, apoyadas en tecnologías emergentes.

Estudiar la forma geométrica de los ciclones tropicales, en el marco del método de Dvorak, es un área con implicaciones teóricas y prácticas profundas. La geometría no es solo un atributo visual: es una manifestación observable de los procesos dinámicos que gobiernan la organización convectiva y, con ella, la distribución e intensidad de la precipitación. Este trabajo mostró una relación entre la geometría de los ciclones y la intensidad de la precipitación, y exploró la utilidad de los patrones de Dvorak como herramienta de análisis morfodinámico.

La geometría explicable de los sistemas precipitantes aporta información útil sobre la intensidad de lluvia en ciclones tropicales. La razón perímetro-diámetro (RSG) y los descriptores relacionados capturan una noción física de compactación que correlaciona con la precipitación media, modal y máxima, y complementan a los estimadores centrados en viento. Por su bajo costo computacional y su claridad física, son candidatos naturales para integrarse en flujos operativos de corto tiempo y apoyar decisiones de alerta temprana.

Como trabajo futuro se propone: (i) validar el enfoque en múltiples cuencas y temporadas, (ii) estandarizar umbrales en unidades físicas (km) y segmentación adaptativa, (iii) fusionar la información geométrica con predictores ambientales y orográficos, y (iv) evaluar el acoplamiento en tiempo real con herramientas operativas de seguimiento de tormentas.

Apéndice A

Análisis de sensibilidad

La Tabla **??** resume las pruebas cruzadas entre distintos tamaños de ventana y umbrales de intensidad de lluvia. En general, umbrales más bajos o ventanas más pequeñas producen más detecciones y viceversa.

Tabla A.1
Número de objetos detectados por intensidad de lluvia y tamaño de ventana.

Intensidad de lluvia (mm/h)	5 píxeles	10 píxeles	20 píxeles	50 píxeles
30	3893	2923	2256	1519
40	3491	2687	2101	1451
50	3419	2654	2090	1460
60	3279	2540	1968	1387
70	3164	2441	1915	1369

Tabla A.2
Porcentaje de varianza explicada (ACP de 2 componentes) para Rain, Mode y Max por intensidad de lluvia y tamaño de ventana.

mm/h	Rain				Mode				Max			
	5 px	10 px	20 px	50 px	5 px	10 px	20 px	50 px	5 px	10 px	20 px	50 px
30	77.40	79.61	80.08	78.94	76.08	78.47	79.13	78.22	78.01	80.64	81.40	80.51
40	77.76	79.73	79.70	78.55	76.42	78.63	78.89	77.99	78.44	80.80	81.10	80.19
50	77.44	79.29	79.60	78.11	76.28	78.40	78.93	77.71	78.24	80.53	81.13	79.91
60	77.35	78.98	79.20	78.32	76.24	78.20	78.67	77.99	77.96	79.99	80.48	79.73
70	77.09	78.76	79.01	78.27	76.15	78.14	78.62	78.16	77.73	79.74	80.21	79.57

- **Rain** (media 78.65): métrica más estable, con rango de desviación [−1,56, +1,43] y desviación estándar aproximada de 0.88.

- **Mode** (media 77.78): rango [−1,70, +2,09] y desviación estándar aproximada de 1.07.
- **Max** (media 79.90): rango [−2,17, +1,50] y desviación estándar aproximada de 1.10.

Tabla A.3
Vista previa del conjunto de datos: 2090 registros y 8 variables.

	RR	CAC	RSG	FF	RF	MR	CA	Rain (media)
1	0.065207	0.616131	1.152256	0.30147	0.40026	0.783499	0.768332	522.371316
2	0.168134	0.512110	0.926109	0.331562	0.284373	0.790743	0.694915	66.610856
3	0.072836	0.544925	0.613198	0.428816	0.161240	0.711123	0.828571	71.071680
4	0.189269	0.524034	0.710681	0.581251	0.293571	0.766087	0.898999	77.886964
5	0.458810	0.605061	0.811115	0.675506	0.444421	0.834784	0.885496	108.083906
				...				
2086	0.239925	0.509584	0.816662	0.545794	0.364010	0.780322	0.812057	103.593554
2087	0.509364	0.677834	0.705976	1.242800	0.619414	0.897059	0.947368	76.053625
2088	0.361507	0.627395	1.146804	0.340765	0.448160	0.853739	0.746207	97.244481
2089	0.143326	0.524079	1.105967	0.396274	0.484708	0.795356	0.779934	198.149218
2090	0.292364	0.594964	0.947910	0.519156	0.466479	0.815600	0.808594	107.562615

Apéndice B

Descripción del algoritmo `AnalysisRainGOES13`

A continuación se presenta una versión en lenguaje natural del algoritmo empleado para procesar los datos de intensidad de lluvia y aplicar ACP y k-means.

1. **Carga de datos.**
   1.1. Cargar todos los archivos CSV disponibles de intensidad de lluvia.
   1.2. Cada archivo se lee como una matriz numérica bidimensional.
2. **Definición del umbral de precipitación.**
   2.1. Para cada archivo CSV se conserva únicamente la información de los píxeles con intensidad de lluvia superior al umbral fijado.
   2.2. Se genera una nueva estructura de datos con la precipitación por encima de dicho umbral.
3. **Segmentación de la imagen.**
   3.1. Sobre el archivo filtrado se identifican regiones continuas de precipitación.
   3.2. Se calcula el área en número de píxeles de cada región.
   3.3. Se conservan únicamente las regiones con área superior al umbral establecido.
4. **Extracción de estadísticas y descriptores.**
   4.1. Para cada región identificada se calculan área, área convexa, perímetro, radio máximo, radio mínimo, intensidad media de lluvia, moda, máximo, mediana, desviación estándar y varianza.

4.2. A partir de estas estadísticas se construyen los descriptores MR, RR, CAC, RSG, FF, RF y CA.

5. **Preparación de datos para ACP.**

   5.1. Se combina la información de todos los archivos en un único conjunto de datos.

   5.2. Cada fila representa una observación y contiene los descriptores geométricos y la variable objetivo de precipitación.

   5.3. Se normalizan las variables.

6. **Aplicación de ACP.**

   6.1. Se ejecutan análisis ACP de dos y tres componentes.

   6.2. Se varían las variables objetivo consideradas (media, moda y máximo).

   6.3. Se obtienen las cargas y las puntuaciones para cada observación.

7. **Clasificación con *k*-means.**

   7.1. Sobre las puntuaciones del ACP se aplica el algoritmo k-means.

   7.2. El número óptimo de grupos se determina mediante el método del codo.

8. **Generación de resultados y visualizaciones.**

   8.1. Se grafican las proyecciones 2D y 3D coloreadas por clúster.

   8.2. Se generan círculos de correlación para interpretar el aporte de cada variable a las componentes.

   8.3. Se presentan tablas y gráficas con la clasificación obtenida y su relación con la intensidad de lluvia.

Apéndice C

Descripción general del proceso computacional

C.1. Planteamiento

El objetivo de la investigación es determinar si la geometría de un sistema nuboso guarda relación con la intensidad de la lluvia que produce. La hipótesis de trabajo sostiene que los patrones geométricos de los sistemas nubosos pueden emplearse para caracterizar la magnitud y frecuencia de la precipitación asociada; a diferencia de la técnica Dvorak –que estima la intensidad de un ciclón tropical a partir de su forma, pero fue desarrollada para el viento y no para la precipitación–, aquí se parte de la intensidad de lluvia medida y se busca su correspondencia con descriptores geométricos calculados sobre la silueta del sistema nuboso.

Para responder a esa pregunta se requiere transformar un conjunto de mapas de precipitación –derivados de imágenes satelitales digitales (ISD) del GOES-13– en una tabla numérica donde cada renglón sea un sistema nuboso y cada columna una medida de su forma o de su lluvia, y después analizar esa tabla con técnicas estadísticas multivariadas. Ese recorrido, del píxel al grupo de sistemas nubosos, es el que implementan los tres programas documentados en estos apéndices.

C.2. Las tres etapas del proceso

El proceso se divide en tres etapas encadenadas, cada una implementada en un programa independiente y documentada en un apéndice propio. La salida de cada etapa es la entrada de la siguiente:

Etapa 1 — Segmentación (Apéndice ??). Toma el mapa de intensidad de lluvia de una escena satelital completa y aísla las regiones donde la precipitación supera

el umbral de lluvia intensa. Cada región conexa se considera un sistema nuboso: se recorta como una imagen binaria independiente y se le calculan propiedades geométricas básicas junto con estadísticas de su intensidad de lluvia (promedio, moda, máximo, mediana, desviación estándar y varianza).

Etapa 2 — Descripción de la forma (Apéndice ??). Recibe cada silueta binaria y calcula sobre ella siete familias de descriptores geométricos: compacidad a partir del perímetro (FF), convexidad mediante el cierre convexo (CA), distancias extremas del contorno (CAC), caja delimitadora y diámetro (RSG), círculo definido por el diámetro (RF), muestreo radial multidireccional (MR) y estadística de radios respecto al centroide (RR). Además de los valores numéricos, genera una imagen por descriptor que permite verificar visualmente cada construcción geométrica.

Etapa 3 — Análisis multivariado (Apéndice ??). Reúne los descriptores de forma y las estadísticas de lluvia de todos los sistemas nubosos en una sola base de datos y busca estructura en ella: agrupa los sistemas con K-Means, reduce la dimensionalidad con análisis de componentes principales (PCA) y evalúa la calidad de los grupos obtenidos mediante el método del codo, el coeficiente de silhouette y un contraste con DBSCAN.

La Figura **??** resume el recorrido completo y la Tabla **??** concentra, para cada etapa, el programa que la implementa, su lenguaje y sus archivos de entrada y salida.

Figura C.1
Flujo general del proceso: de los mapas de intensidad de lluvia a los grupos de sistemas nubosos. Los recuadros azules corresponden a los datos que circulan entre etapas y los grises a los programas documentados en cada apéndice.

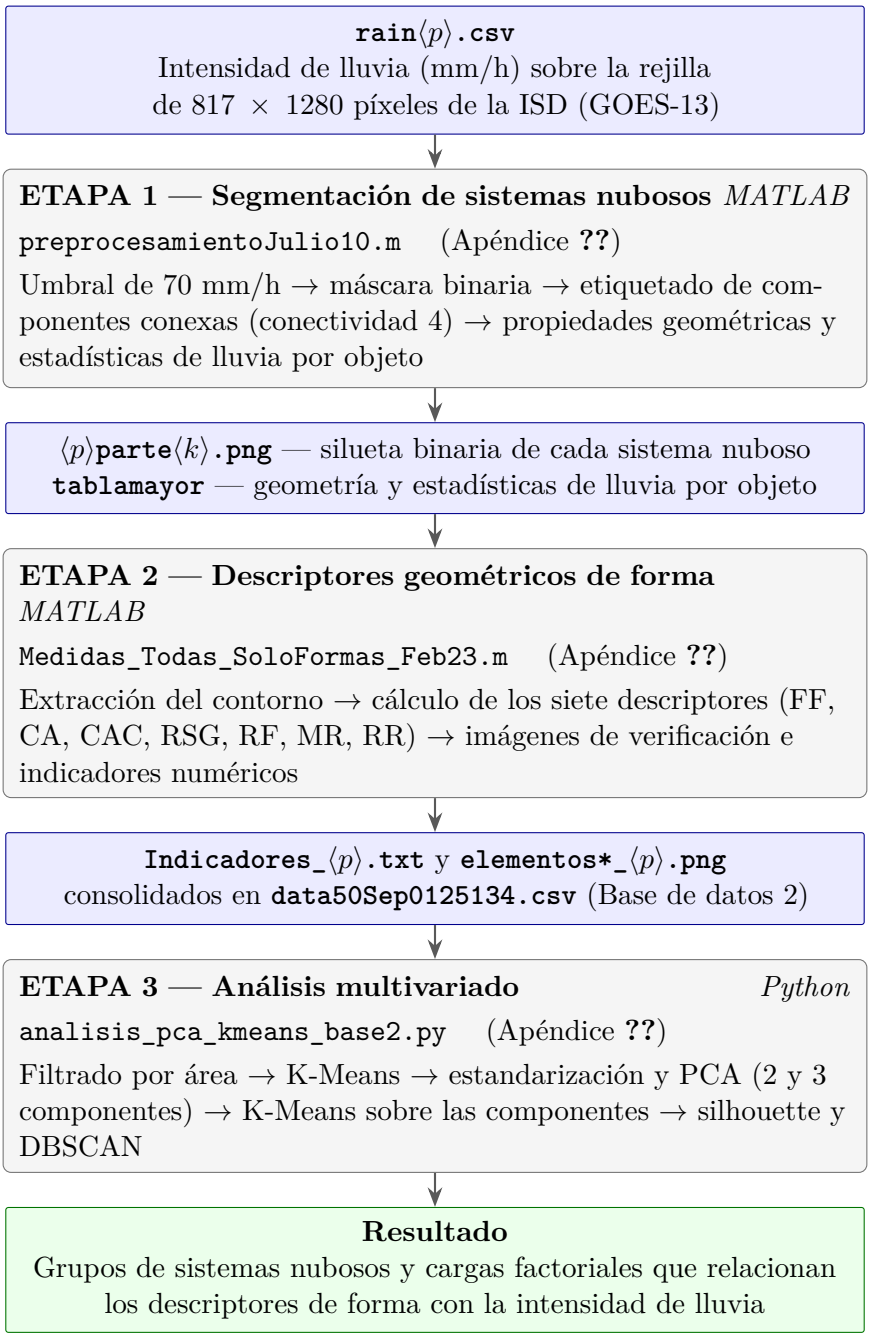


Tabla C.1
Programas que integran el proceso, con sus insumos y productos.

Etapa	Lenguaje	Entrada	Salida principal
1. Segmentación	MATLAB	`rain`⟨p⟩`.csv`	Siluetas binarias por objeto y tabla de propiedades
2. Descriptores de forma	MATLAB	`caja_bw_`⟨p⟩`.png`	`Indicadores_`⟨p⟩`.txt` e imágenes de verificación
3. Análisis multivariado	Python	`data50Sep0125134.csv`	Agrupamientos, componentes principales y gráficas

C.3. Los datos utilizados

Las escenas procesadas corresponden al periodo del 22 de octubre de 2015 a las 00:15 h al 24 de octubre de 2015 a las 20:15 h, durante el cual el huracán Patricia pasó de categoría I a categoría V y de nuevo a categoría I. Ese intervalo resulta conveniente para el estudio porque un mismo sistema recorre casi todo el rango de intensidades posibles, lo que permite observar cómo cambia su geometría conforme cambia la precipitación que produce.

Las imágenes provienen del satélite GOES-13, proporcionadas por el área de Percepción Remota del Servicio Meteorológico Nacional, con una resolución temporal de 15 minutos y un tamaño de píxel de 2.36 km por lado. El umbral de 70 mm/h empleado en la Etapa 1 corresponde al valor a partir del cual la precipitación se considera intensa.

Apéndice D

Artículo publicado

Los resultados centrales de esta tesis se publicaron en la revista *ISPRS International Journal of Geo-Information* (MDPI), indizada en el Journal Citation Reports. La referencia completa del artículo es:

> Garcia, I. G., Gutierrez-Lopez, A., Herrera Navarro, A. M., & Jimenez-Hernandez, H. (2025). Hurricane Precipitation Intensity as a Function of Geometric Shape: The Evolution of Dvorak Geometries. *ISPRS International Journal of Geo-Information*, *14*(11), 443. https://doi.org/10.3390/ijgi14110443

El artículo desarrolla la propuesta de los descriptores CAC y RSG, su comparación con los descriptores clásicos de forma y el análisis de componentes principales sobre el caso del huracán Patricia, material que corresponde a los Capítulos 5 y 6 de este documento. A continuación se reproduce la versión publicada en su formato editorial.

International Journal of Geo-Information

MDPI

Article

Hurricane Precipitation Intensity as a Function of Geometric Shape: The Evolution of Dvorak Geometries

Ivan Gonzalez Garcia [1], Alfonso Gutierrez-Lopez [2,3,*], Ana Marcela Herrera Navarro [1] and Hugo Jimenez-Hernandez [1]

[1] Facultad de Informatica, Autonomous University of Queretaro, Juriquilla, Santiago de Querétaro 76230, Queretaro, Mexico; ivan.glez@uaq.mx (I.G.G.); mherrera@uaq.mx (A.M.H.N.); hugo.jimenez@uaq.mx (H.J.-H.)
[2] Water Research Center, International Flood Initiative, Latin-American and the Caribbean Region (IFI-LAC), Intergovernmental Hydrological Programme (IHP), Autonomous University of Queretaro, Santiago de Querétaro 76010, Queretaro, Mexico
[3] Mexican Institute of Water Technology (IMTA), Water Security Head Office, Paseo Cuauhnahuac 8532, Col. Progreso, Jiutepec 62550, Morelos, Mexico
* Correspondence: alfonso.gutierrez@uaq.mx

Abstract

The Dvorak technique has represented a fundamental tool for understanding the power of tropical cyclones based on their shape and geometric evolution. However, it should be noted that the Dvorak technique is purely morphological in nature and was developed for wind, not precipitation. The role of shape methods in precipitation prediction remains uncertain, particularly in the context of modern multi-sensor capabilities. This uncertainty forms the motivation for the present study. In an attempt to enrich Dvorak's technique, this study proposes a novel hypothesis. This study tests the hypothesis that higher precipitation intensity is associated with more organized cloud-system morphology, as captured by simple geometric descriptors and indicative of dynamically coherent convection. A total of 3419 cloud-system objects (after size filter) were utilized to establish geometric relationships in each of them. For the case study of Hurricane Patricia over the Mexican coast in 2015, 3858 geometric shapes were processed. The cloud-system morphology was derived from geostationary imagery (GOES-13) and collocated with satellite precipitation estimates in order to isolate intense-rainfall objects (>50 mm/h). For each object, simple geometric descriptors were computed, and shape variability was summarised via Principal Component Analysis (PCA). The present study sought to evaluate the associations with rain-rate metrics (mean, mode, maximum) using rank correlations and k-means clustering. Furthermore, sensitivity analyses were conducted on the rain threshold and minimum object size. A Shape Descriptor: ratio between perimeter and diameter was identified as a promising tool to enhance early prediction models of extreme rainfall, contributing to enhanced meteorological risk management. The study indicates that cloud shape can serve as a valuable indicator in the classification and forecasting of intense cloud systems.

Keywords: rainfall intensity; Dvorak technique; principal component analysis; shape descriptors; satellite image segmentation

check for updates

Academic Editors: Wolfgang Kainz, Andriani Skopeliti, Ioannis Giannopoulos, Vassilios Krassanakis and Guillaume Touya

Received: 23 June 2025
Revised: 29 September 2025
Accepted: 4 November 2025
Published: 8 November 2025

Citation: Garcia, I.G.; Gutierrez-Lopez, A.; Navarro, A.M.H.; Jimenez-Hernandez, H. Hurricane Precipitation Intensity as a Function of Geometric Shape: The Evolution of Dvorak Geometries. *ISPRS Int. J. Geo-Inf.* **2025**, *14*, 443. https://doi.org/10.3390/ijgi14110443

Copyright: © 2025 by the authors. Published by MDPI on behalf of the International Society for Photogrammetry and Remote Sensing. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

1. Introduction

The characterization of tropical cyclones by satellite observations has evolved substantially since the 1970s, marking a turning point in operational meteorology. A significant

contribution is the Dvorak technique, a visual method primarily developed by [1,2], which enables the maximum wind speed intensity of tropical cyclones to be estimated based on the identification of specific cloud patterns in satellite images. Although the technique was initially conceived as a practical tool to compensate for the absence of in situ data on offshore cyclones, it has over time demonstrated a remarkable degree of correlation with fundamental physical parameters, particularly minimum central pressure and maximum wind speed [3,4]. Notwithstanding the extensive and sustained utilization of the method, a gap remains in terms of a precise understanding of the geometric shapes underlying the Dvorak patterns and their relationship to precipitation intensity. This relationship, which involves mesoscale dynamics, convective symmetry, and atmospheric feedback mechanisms, represents a critical area of study for the improvement of hydrometeorological predictions in contexts of climate vulnerability. The Dvorak technique is predicated on the premise that there is a functional relationship between the organization of the deep cloudiness detected in the infrared or visible spectrum and the intensity of the cyclone. This relationship is represented by the "development patterns" scheme, among which the "curved band" patterns, the "central dense overcast" pattern, and the "embedded center" or "annular pattern" stand out. These sequences, in essence, obtain geometric representations that facilitate structural inferences about the system. For instance, the presence of a distinctly delineated and symmetrical eye is indicative of a severe cyclone, commonly associated with sustained intensification and an exceptionally organized convective core [4]. Subsequent studies have shown that these geometric patterns relate to storm intensity and to the spatial organization of cyclone precipitation [5]. Here we extend this line of work by quantifying the relationship between geometric descriptors and rainfall intensity (mm/h).

Over the last decade, operational approaches for estimating tropical cyclone intensity from satellite imagery have been updated, with a predominant emphasis on wind (e.g., variants of the Dvorak method). At the same time, evidence has shown that the shape of precipitation systems is associated with rainfall intensity; however, descriptors of the geometric shape of storms have been rarely used. For Mexico and the eastern Pacific, several studies have documented the contribution of tropical cyclones to seasonal rainfall and hydrometeorological extremes. These studies emphasise that the magnitude of precipitation does not necessarily scale with wind categories. Building on this body of knowledge, our work evaluates whether simple geometric descriptors of cloud/rain contours can offer an early, interpretable, and low-cost indicator of extreme rainfall potential, complementing wind-centered estimators.

Scientific interest in the geometric shape of cyclones is not only descriptive, but also responds to a need to link their morphology with their internal dynamics. The shape of a hurricane, particularly the symmetry of its spiral bands and the clarity of its eye, has direct implications for internal convective processes and the radial distribution of precipitation. The paper utilised spatial metrics and satellite segmentation to establish a correlation between the shapes of rain groups. As Houze [6] and Schiesser [7] have noted, mesoscale convective systems exhibit a spatial organization whose structure is crucial for effective precipitation. In the context of tropical cyclones, this organization adopts shapes that are susceptible to visual classification by techniques such as Dvorak. This allows the observed geometry to be used as a preliminary, though visual, estimate of the thermodynamic properties of the system.

Nevertheless, the technique has been the subject of extensive discussion and has required revisions. The reliance on visual perception and the subjectivity of the analyst has led to the development of objective and semi-automatic methods. These include the Advanced Dvorak Technique (ADT), which implements edge detection algorithms, band segmentation, and symmetry analysis to generate a more reproducible estimate of

intensity [8,9]. This transition to automated geometric analysis has led to new research opportunities, focusing on quantifying the relationship between the spatial shape of the cyclone and its precipitable capacity.

From a climatological perspective, the geometric shape of tropical cyclones has shown significant variability depending on the oceanic environment and the latitude of formation. Kossin et al. [10] reported a migration towards the poles in cyclone intensity maxima. This phenomenon is accompanied by structural changes in the symmetry of the systems. Kawabata et al. [11] utilized a 30-year Dvorak-based reanalysis in the Western Pacific region to confirm an increase in the proportion of cyclones exhibiting annular geometric structures. This phenomenon may be linked to alterations in the thermodynamic conditions of the ocean and atmosphere. This morphological evolution could directly impact regional patterns of extreme precipitation, making the analysis of shape as a predictive variable even more relevant.

With regard to wind speed, it should be noted that the Dvorak technique can sometimes present systematic biases. Research by [12,13] demonstrated a correlation between errors in wind speed estimation and the shape of the cyclone. Specifically, cyclones that are more asymmetrical or those with poorly defined bands tend to be underestimated in intensity. It is important to note that the focus here is on the intensity of the system, not the intensity of the precipitation. This suggests that geometric ambiguity can affect the accuracy of the method and obscure critical signals about the cyclone's danger. In parallel, Ref. [14] compared Dvorak parameter estimates across different meteorological agencies, revealing inconsistencies related to the interpretation of cloud shapes.

The most recent results [5] analyze the rainfall patterns of tropical cyclones that made landfall in the North Atlantic using spatial metrics and satellite data (1998–2014). Five key metrics (area, solidity, dispersion, closure, roundness) were selected to distinguish rainfall patterns according to storm intensity. The study revealed regional variations in cyclonic precipitation, influenced by wind shear, humidity, and interaction with land [5]. Among the most pioneering studies, Ref. [15] highlights that shape analysis studies objects in meteorology and climatology, such as tropical cyclones and atmospheric rivers, using metrics that quantify size and shape. The application of this technology is centered on two key areas: forecast verification, which involves the comparison of models with observations, and process studies, which analyze the structure of climatic phenomena. The present work contributes to the first area.

As outlined above, it is imperative to identify the morphological characteristics of cyclones that directly impact the intensity of precipitation resulting from rain produced by a cloud system. This is exemplified by the relationship between perimeter and diameter. The aim is to improve the classification of cloud systems, facilitate the analysis of satellite data, capture the relationship between cloud morphology and precipitation processes, and promote the use of machine learning techniques in meteorology.

Operationally, Dvorak-type analyses prioritise wind intensity; however, effective risk management requires early warning signs of extreme rainfall, which is the main trigger of impacts. We hereby propose a hypothesis that investigates the correlation between geometric descriptors of storm shape and rainfall metrics (mean, mode, and maximum). Therefore, related descriptors are analysed and evaluated based on thousands of segmented contours. The application of PCA allows us to identify dominant modes of geometric variability. Our contribution is an explainable morphological predictor that can be integrated into storm tracking and forecasting systems. This will allow configurations with the highest precipitation potential to be identified at an early stage.

2. Materials and Methods

2.1. Database

The work uses a database consisting of 134 .CSV files, each containing a rainfall intensity matrix (817 × 1280 pixels) in mm/h per pixel. These files come from a processing method presented in [16], which proposes a technique to associate rainfall intensity matrices with digital satellite images, using the Hydroestimator method.

In that work, the materials consist of digital satellite images acquired by the geostationary meteorological satellite GOES-13, which covers Mexico and captures imagery at 15 min intervals. The ISD frames have an 8-bit radiometric resolution. Each image spans 817 pixels in latitude by 1280 pixels in longitude, with a pixel size of 2.36 km per side. As part of the methodology in [16], datasets from environmental meteorological stations located within the study area are used to validate the per-pixel rainfall-intensity matrix.

The database contains image segmentation from 12:15 a.m. on 22 October 2015 to 8:15 p.m. on 24 October 2015. During this period, the hurricane transitioned from Category I to Category V and then back to Category I, with a total of 134 files, each containing information on rainfall intensity. In this analysis, we propose applying the Principal Component Analysis (PCA) method to identify correlations between the variables in the dataset and the target variable. Furthermore, the analysis aims to identify the variables that have a significant impact on explaining the phenomenon under study.

In order to reduce pixelation bias, only contours with an effective diameter of at least 5 pixels (approximately an area of 20 pixels) are analysed. This threshold is used because metrics based on the perimeter or diameter show numerical stability above it. This criterion (filter) preserves synoptic-scale precipitation structures, as well as maintaining consistency across all tests.

2.2. Hurricane Patricia

The selected this research focuses on analyzing to Hurriane Patricia, which took place from 20 to 24 October 2015, on the Pacific coast of Mexico. This hurricane evolved to category-5 on the Saffir-Simpson scale and is considered the most intense hurricane ever recorded in terms of atmospheric pressure and sustained winds, indicating that it was a hurricane of great intensity and extreme danger [17]. In the work presented in [16], a method is developed to associate a rainfall intensity matrix with a digital satellite image using the Hydroestimator Method. Using the intensity matrices as a reference, a projection of the meteorological phenomenon is created, taking rainfall intensity into account. Each of the matrices is saved in a .CSV file. Each file corresponds to a digital satellite image at a specific moment in time of the phenomenon, corresponding to images taken by the geostationary operational environmental satellite east (GOES 13). The image spans 817 pixels in the latitude direction and 1280 pixels in the longitude direction; each pixel measures 2.36 km per side. Using the intensity matrix as a reference, the cloud systems are modelled for extreme rainfall intensity values. Derived from the work carried out by (Table 5 in [18]), only values above 50 mm/h in rainfall intensity are selected, which produces cloud systems that are translated into binary images through processing. This process generates a binary image with the shape of the cloud system for each of the matrices. It is on these shapes that we wish to test the proposed hypothesis. The initial phase involves the segmentation of images to create a database of all the cloud systems observed in the phenomenon, along with the proposed characteristics. We processed 3419 cloud-system objects whose binary masks contain more than five pixels (minimum area threshold = 5 px) at the image resolution (2.36 km per pixel). To evaluate robustness, we performed cross-tests with different pixel-window sizes (5, 10, 20, 50 px) and rainfall thresholds (e.g., 30–70 mm/h) (see Appendix A).

2.3. Hydroestimator

The Hydroestimator (HE) is an operational approach that estimates rainfall rate (mm/h) from geostationary IR (channel-4) imagery. Its main purpose is to provide near–real-time precipitation fields over regions with limited radar coverage, enabling now-casting and monitoring of convective systems such as tropical cyclones. Inputs/outputs. Input: pixel-wise cloud-top brightness/temperature (B) from IR-4. Output: pixel-wise rainfall rate R (mm/h) and, optionally, hourly averages per pixel [19].

The proposals were formulated based on three distinct target variables: rainfall intensity, mode, and maximum value. The mode corresponds to the most frequent value recorded among the set of pixels that constitute the shape under study, and the maximum value corresponds to the highest rainfall intensity within the cloud system shape.

3. Geometry of Variables

The measurements presented below were considered because they depend on basic elements of a two-dimensional shape: area, perimeter, diameter, and radius. Geometric descriptors exhibit collinearity (e.g., perimeter-diameter, roundness, compactness). In order to synthesise the information and preserve physical interpretability, we applied PCA to the correlation matrix. In selecting components, we prioritised those with a minimum of 80% cumulative variance. We employed correlation circles to ascertain which groups of descriptors are associated with rainfall metrics (mean, mode, maximum). This approach, which is standard in atmospheric sciences, produces stable orthogonal axes that summarise the dominant variability of shape and facilitate its relationship with precipitation intensity (see Table 1).

Table 1. Shape and rainfall variables.

Parameter	Description
Area	Area of the shape
ConvexArea	Area of the convex envelope
Perimeter	Perimeter of the shape
radio_max	Maximum radius of the region
radio_min	Minimum radius of the region
Rain	Mean associated rainfall intensity.
Mode	Most frequent rainfall intensity value in the analyzed region
Max	Maximum rainfall intensity value in the region
Median	Median rainfall intensity value in the region
Dstandard	Standard deviation of rainfall intensity values
Variance	Variance of rainfall intensity values in the region

3.1. Scale and Computation of Descriptors

Scale and computation of descriptors. Shape descriptors (FF, RF, RR, CAC, RSG) were computed in pixel units over binary masks. The area A is the number of object pixels, and the perimeter P is the number of boundary pixels (8-connectivity). Diameters D, d, and dmax are expressed in pixels. With these consistent units, the descriptors are dimesionless and scale-invariant within the same grid.

3.2. Descriptors

3.2.1. Comparison Between Area and Perimeter

The most commonly used measure of circularity corresponds to the one proposed in [20]. Also called the Shape Factor (also known as the circularity index), it is calculated using the following relationship:

$$\mathrm{FF} = \frac{A}{A_p} = \frac{4\pi A}{P^2} \tag{1}$$

where A is the area of the object, A_p is the area of the circle with the same perimeter as the object, and P is the perimeter of the object.

3.2.2. Comparison Between Area and Diameter

The following is a measure proposed in [21], given by:

$$RF = \frac{A}{A_{max}} = \frac{4A}{\pi d_{max}^2} \tag{2}$$

where A is the area of the object, A_{max} is the area of the circle with the maximum diameter of the object, and d_{max} is the maximum diameter, defined as the largest length between two points on the edge of the object.

3.2.3. Relationship Between Radii

A measure of circularity defined on a relationship between two radii is proposed in [22], defined as follows:

$$RR = \frac{r_{min}}{r_{max}} \tag{3}$$

where r_{min} is the minimum radius, defined as the minimum distance from the centroid of the edges to the edge and r_{max} is the maximum radius, defined as the maximum distance from the centroid to the edge of the shape.

3.2.4. Measure of Roundness

Another measure associated with the relationship between radii is proposed in [22], defined as:

$$MR = \frac{1}{n}\sum_{j=1}^{n} \frac{\overline{r_b}}{|r_j - \overline{r_b}| + \overline{r_b}} \tag{4}$$

where $\overline{r_b}$ is the average of the radii from the edge to the centroid and r_j is the radius relative to the $j-$th pixel of the edge.

3.2.5. Convexity Measurement

One way to describe the shape of an object is by definition convexity. One way of measuring convexity is by the ratio between the area of the object and the area of its convex hull. Some variants for polygons can be found in [23]. The convexity of a shape is defined as:

$$CA = \frac{A(K)}{A_H(K)} \tag{5}$$

where K denotes the shape, $A(K)$ represents the area of K, and A_H represents the area of the convex hull of K.

3.3. Proposed Shape Descriptors

Below are a couple of proposals for characterizing cloud shapes. A body of constant width is one that has the same width in all directions. The width of an object in a given direction is the distance between a pair of parallel lines that are tangent to the object. For a fixed width, the body of constant width with the largest area is known to be a circle, so these relationships also help us measure an object's circularity. In the geometric convex, bodies of constant width have unique properties that make them stand out in convex geometry. A result presented in [24] states that:

Lemma 1. *Let K be a convex and closed curve in the plane. If for every point $p \in \partial K$, the largest chord through p always has constant length, then K is of constant width.*

This proposition provides a characterization of bodies of constant width based on measuring the width from each point on the edge of the shape. In this characterization, a shape that satisfies this property is the circle. In the circle, for each point a diameter can be defined, which corresponds to the largest chord through the point. Since all diameters in a circle are equal, the circle is of constant width. However, there are figures that satisfy this property that are not circles. We define the descriptor based on this property as follows:

Lemma 2. *Let p_i and p_j two points on the edge of a shape A with $i, j \in I$, where I is the set of all points on the edge of the shape, let $d_i = max\{|p_i - p_k|\}$ for $k \in I$, and let $D = max\{d_i \mid i \in I\}$ and $d = min\{d_i \mid i \in I\}$.*

We define the following measure of circularity by constant width as:

$$CAC = \frac{d}{D} \tag{6}$$

where d corresponds to the minimum of the largest distances of the points on the edge and D to the maximum. If CAC is 1, then the object is a body of constant width, and if it is close to 0, the object is a point. The range of this measure is in the interval [0, 1]. This measure is based on the contour of the shape, and because of the way it is defined; it is invariant to rotation and scale.

Relationship Between Perimeter and Diameter

In [25], the following property of is established for a simple closed curve.

Lemma 3. *Every convex and closed curve in the plane, of length L and diameter D, satisfies $L \leq \pi D$. Equality is achieved if and only if the curve has constant width D.*

The proposition gives us an inequality for convex curves in the plane. Here, D is defined as the largest length between two points on the edge of the object.

However, the proposed inequality is very simple compared to the isoperimetric inequality. From the inequality $L \leq \pi D$, we can formulate that the length of the chord is always less than πD. For convex curves, if we take the quotient of the smaller value between the larger value, it will always be a number between 0 and 1. From this, we can define a measure of shapes that relates their perimeter and diameter.

$$RSG = \frac{P}{\pi D} \tag{7}$$

where P corresponds to the perimeter of the shape and D to the diameter. From the inequality, we obtain that the domain of this measure is in the interval [0, 1], where a value close to 1 indicates that the object is of constant width.

The two proposed descriptors allow us to measure how close a shape is to an object of constant width.

The data in Table 2 correspond to the descriptors (factor) used to perform the classification and implementation of the PCA. The variables MR, RR, CAC, RSG, FF, and RF correspond to circularity descriptors, and CA is used to measure the convexity or compactness of a shape.

Table 2. Equation of parameters.

Factor	Equation	Description
MR	$MR = \frac{1}{n}\sum_{j=1}^{n} \frac{\overline{r_b}}{\lvert r_j - \overline{r_b}\rvert + \overline{r_b}}$	Average roundness
RR	$RR = \frac{r_{min}}{r_{max}}$	Measurement of circularity based on the ratio of radii
CAC	$CAC = \frac{d}{D}$	Measurement of circularity based on width and diameter
RSG	$RSG = \frac{P}{\pi D}$	Ratio of perimeter to diameter
FF	$FF = \frac{4\pi A}{P^2}$	Shape factor
RF	$RF = \frac{4A}{\pi d_{max}^2}$	Roundness factor
CA	$CA = \frac{A(K)}{A_H(K)}$	Measurement of convexity based on area

3.4. Shapes Within the Cloud System

Figure 1 presents a digital satellite image captured by the GOES-13 satellite, illustrating the most intense cloud systems generated from the processing of the information. These systems have been superimposed on the image. It is these regions that are characterized by extreme rainfall.

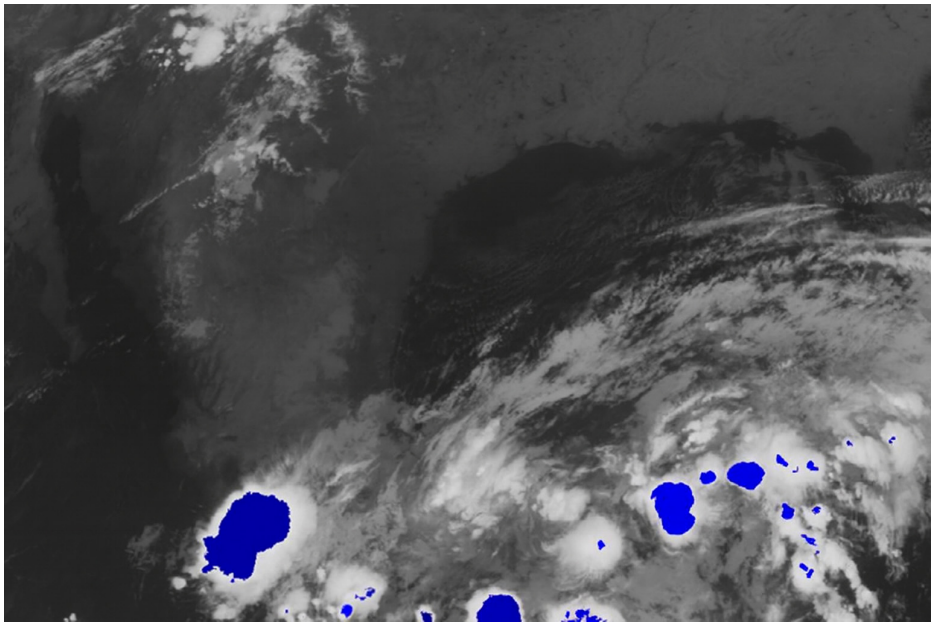


Figure 1. Areas of Extreme Rainfall (≥50 mm/h) in Hurricane Patricia—19 October 2015, 09:15 UTC.

Figure 2 shows a grayscale satellite image, illustrating cloud formations of varying densities across the scene. At the base, multiple cloud formations of a more intense nature (indicating greater density or thickness) are observable, with red outlines delineating specific regions. The application of red outlines to the map serves to denote regions characterised by elevated rainfall intensity, i.e., areas where precipitation is predicted to be particularly substantial. The contrast between the dark background (possibly land or ocean with lower reflectivity) and the light clouds facilitates the identification of cloud formations, while the red outlines clearly indicate the areas of greatest meteorological interest (see details in Table 3).

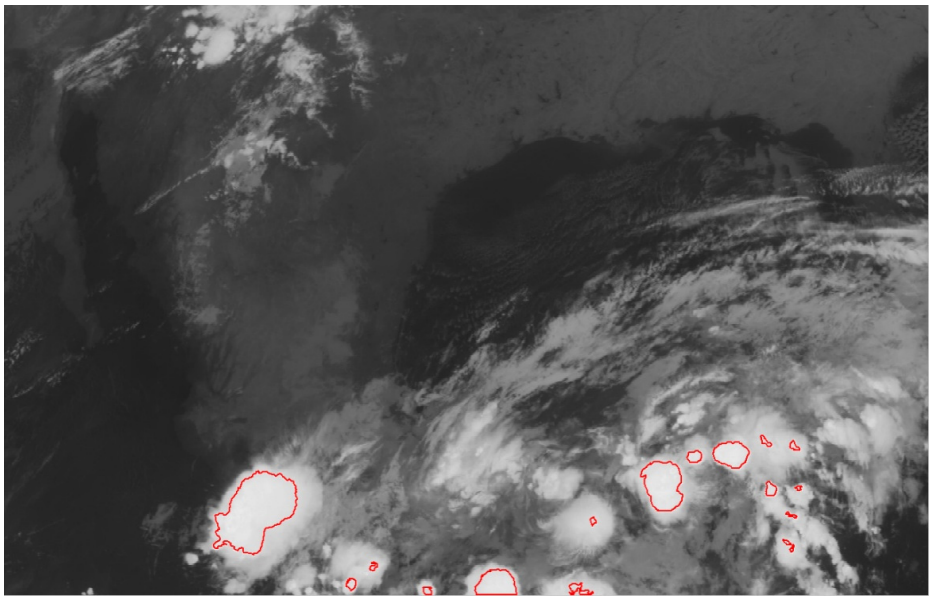


Figure 2. Segmentation of regions with higher rainfall intensity. The red contours outline the areas identified by the algorithm as regions with stronger rainfall intensity.

In Table 4, a comparison is drawn between different shapes descriptors (acronyms such as FF, RF, RR, CA, MR, CAC, RSG) applied to cloud clippings obtained from a digital satellite image. Each row corresponds to a particular shape descriptor, and each column shows:

i. The image displays a representation of the cloud, with its outline highlighted in red.
ii. It is hypothesized that the mark, which is possibly blue, may represent either the bounding circle or some geometric reference.
iii. In certain instances, centroids or principal axes are denoted by lines or dots.

Table 3. Shape descriptor.

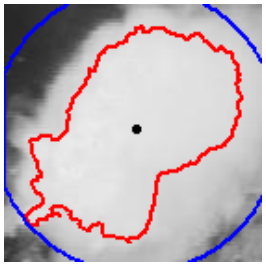
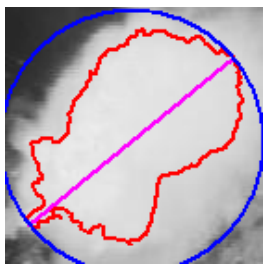
Shape-Factor	Figure	Description	Value
FF		Object area: The area of the circle with a perimeter of 18,654.67 is equivalent to 8204. The indicator is obtained by dividing the object area by the area of the circle with the same perimeter, thus enabling the degree of circularity of the cloud to be assessed in conditions of heavy rain. The image displays a segment of a digital satellite image, with the overlay superimposed.	0.44
RF		In this image, the cloud is delineated in red and encapsulated within a blue circle, the diameter of which corresponds to the maximum distance between two points on the contour (the magenta line). In order to obtain the indicator, the area of the delineated circle (16,180.77) is compared with that of the object itself (8204). This ratio enables the quantification of the proportion of the circle defined by its largest extent that is comprised by the object, thereby providing a fundamental metric of its compactness or dispersion with respect to the circumference that encompasses it.	0.51

Table 3. *Cont.*

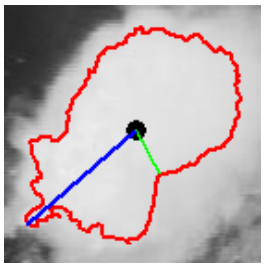
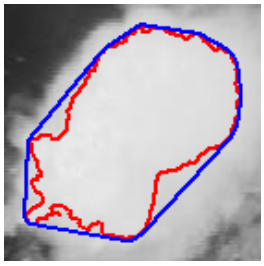
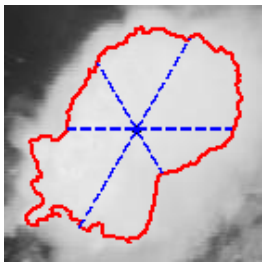
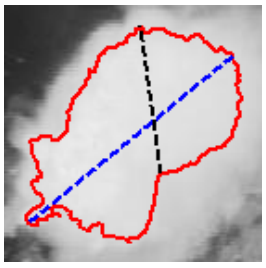
Shape-Factor	Figure	Description	Value
RR		The image displays a cloud clipping, which has been highlighted in red, along with a black dot in the centre, which represents the centroid of the object. The coloured lines indicate the shortest and longest distances from the centroid to the outline, whose values are 26.97 and 77.54, respectively. The descriptor is obtained by calculating the relationship between the smallest radius and the largest radius, thus providing a simple measure of the shape of the cloud, as it compares its minimum and maximum extent from the centre.	0.35
CA		The image illustrates the cloud's outline in red, while the convex hull, delineated in blue, signifies the smallest convex polygon capable of fully enclosing the cloud. In this regard, the area of the cloud (8204) is compared with that of the convex polygon (9590) to define an indicator that measures the compactness of the object. It is evident that the proximity of the cloud's area to its convex hull directly correlates with the compactness of its shape.	0.86
MR		The image illustrates the cloud outlined in red, with multiple blue lines extending from a central point towards the edge, thereby measuring distinct radii. It is evident that an average of 53.18 is derived from these individual values. This average is then utilized to develop an indicator that is employed to compare each radius with the said average. The purpose of this comparison is to evaluate the degree to which the shape of the cloud approximates a uniform radial distribution. Consequently, the resulting descriptor furnishes a rudimentary reference for the regularity or symmetry of the contour with respect to the centre.	0.86
CAC		The image under consideration features a red outline demarcating the area of maximum rainfall intensity. Two dotted lines have been drawn on this outline: the blue line represents the greatest distance between two points on the edge (143.53), while the black line indicates the minimum distance (80.75) within the set of maximum possible distances. The descriptor is defined as the ratio between that minimum distance and the maximum distance, thus providing a measure of the uniformity or elongation of the cloud shape, as evidenced by the comparison between its longest separation and the shortest of the large separations detected.	0.56

Table 3. *Cont.*

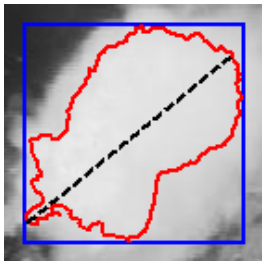
Shape-Factor	Figure	Description	Value
RSG		The image displays a cloud clipping, with the region of maximum rainfall intensity delineated in red, and a black dotted line denoting the maximum distance between two points on the contour, which is 143.53, while the total perimeter is 484. The proposed descriptor is obtained by relating the perimeter to the maximum distance and the constant pi, thus allowing for a simple measurement of the object's shape using only two parameters. This approach ensures that the total length of the contour and the greatest separation within that contour are all that is required to provide a practical and easily calculable indicator in image processing applications.	0.96

Table 4. Factors characterizing cloud morphology.

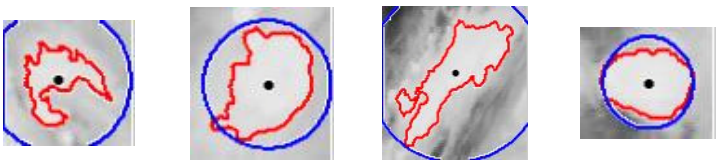
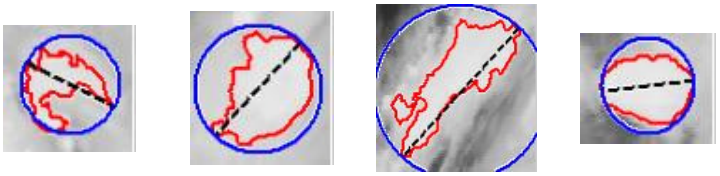
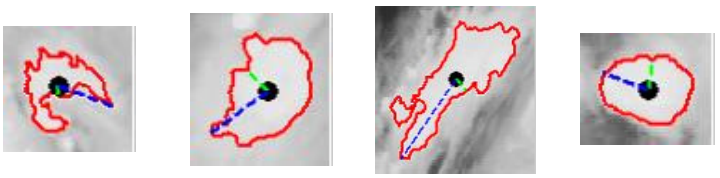
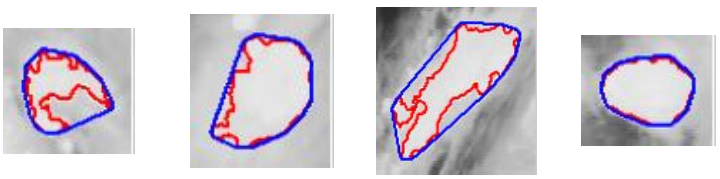
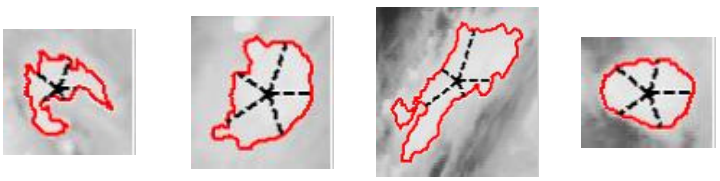
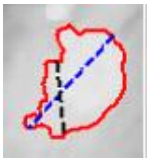
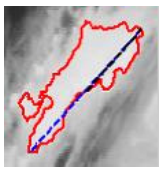
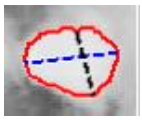
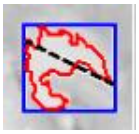
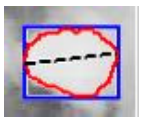
Shape-Factor	Examples of Cloud Systems with Their Shape-Factor Values			
FF		0.18	0.53	0.20	0.73
RF		0.40	0.54	0.25	0.68
RR		0.13	0.41	0.15	0.58
CA		0.57	0.85	0.66	0.93
MR		0.82	0.86	0.77	0.9

Table 4. *Cont.*

Shape-Factor	Examples of Cloud Systems with Their Shape-Factor Values			
CAC				
	0.54	0.60	0.5	0.69
RSG				
	1.48	1.01	1.11	0.96

As illustrated below each image, a numerical value is assigned to the descriptor for that particular cloud. These values reflect different aspects of the cloud's geometry, such as its compactness, elongation, circularity, or other shape properties. Consequently, Table 4 offers a visual (through images) and numerical (through values) comparison of how each descriptor characterizes the morphology of the clouds in the satellite image.

In the course of the study on the evolution of the hurricane that occurred from 22 to 24 October 2015, an analysis was carried out on the basis of satellite images from the GOES-13 satellite. The images employed for the analysis extend over a particular time interval from 12:15 am on the 22nd to 8:15 pm on the 24th, during which period the hurricane underwent a transition from Category I to Category V and subsequently back down to Category I. In order to achieve a detailed analysis, the algorithm called AnalysisRainGOES13 was utilized. The primary objective of this algorithm is to process rainfall intensity data obtained through satellite image segmentation. The processing involved the application of PCA and classification using the k-means clustering algorithm. The processed data is contained in a set of CSV files, which correspond to images with dimensions of 817 × 1280 pixels each. Appendix B provides a comprehensive overview of the pseudo-code employed in the implemented algorithm.

4. Results

The results obtained from applying the PCA method to the database containing the different descriptors are presented below. In this initial analysis, the target variable is rainfall intensity, referred to as Rainfall in the database. Rainfall intensity is associated with the average of the intensities recorded for each pixel that constitutes the shape of each cloud system. As illustrated in Figure 3, the centroids of each group are marked with a black cross. It is evident that the groups are well differentiated, indicating that the segmentation performed is reasonable. The number of clusters was chosen using the elbow method. The cumulative normalized distortion shows a clear change in slope up to k = 4; beyond that, improvements are marginal. For parsimony [26], we adopt k = 4, which captures approximately 86–91% of the total without over-segmentation.

It is illustrated in Table 5, the contribution of each variable to each of the principal components is demonstrated. It is evident that for principal component 1, the variables RR, FF, RF, and CA exhibit the most substantial positive contribution, while RSG contributes significantly negatively. In contrast, principal component 2 is predominantly influenced by the

variables Rainfall and K_means, which exhibit a significant positive contribution. A color scale is employed to denote the contribution of each variable to each principal component. In this instance, 74% of the observed variance is accounted for by both components.

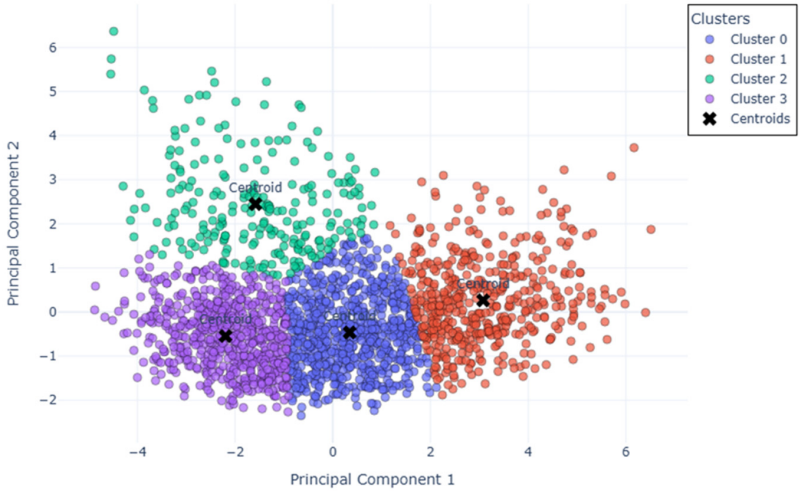


Figure 3. Two-dimensional visualization of K-Means in the PCA space.

Table 5. Two-component projections. All continuous predictors were standardized (z-score; $\mu = 0$, $\sigma = 1$) using StandardScaler (scikit-learn).

Factor	PCA-1	PCA-2
RR	0.41823995	0.14476456
CAC	0.36728841	0.31005496
RSG	−0.28502252	0.57335478
FF	0.39736106	−0.24989648
RF	0.38652358	0.28018747
MR	0.35730487	0.31767739
CA	0.38685201	−0.12561905
Rain	−0.15594614	0.54453752

The third principal was applied to explore the data, thus enabling the observation of the contribution of each variable to each component, as illustrated in Table 6. A Principal Component Analysis was conducted, resulting in the identification of three principal components. The percentage of explained variance was found to be 84%. As illustrated in Table 6, the positive or negative contribution of each variable to each component is demonstrated.

Table 6. Projections in three components.

Factor	PC1	PC2	PC3
RR	0.41823995	0.14476456	−0.02901164
CAC	0.36728841	0.31005496	−0.18264375
RSG	−0.28502252	0.57335478	−0.24402476
FF	0.39736106	−0.24989648	0.21561371
RF	0.38652358	0.28018747	−0.14973593
MR	0.35730487	0.31767739	−0.20501669
CA	0.38685201	−0.12561905	0.45230733
Rain	−0.15594614	0.54453752	0.76858807

As demonstrated in Figure 4, the incorporation of a novel principal component facilitates enhanced separation of the groups. The five proposed groups are clearly delineated, suggesting that the K-means method produced a satisfactory grouping.

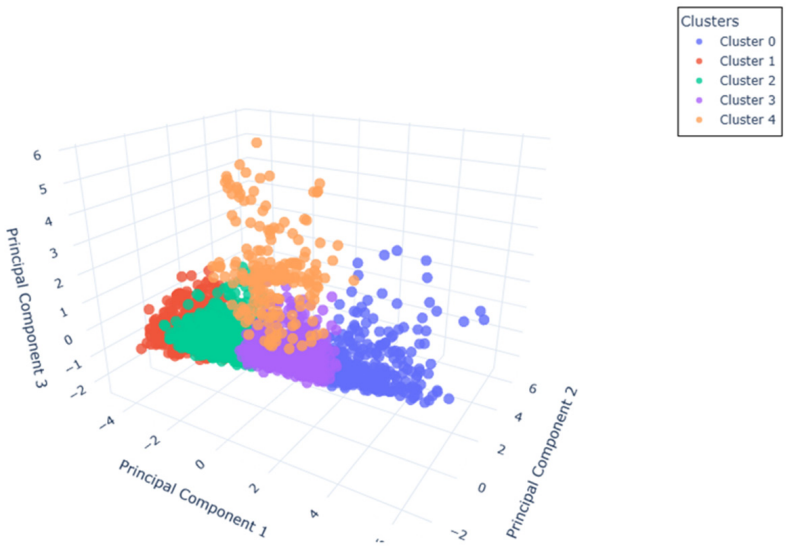


Figure 4. Three-dimensional visualization of K-Means in the PCA space.

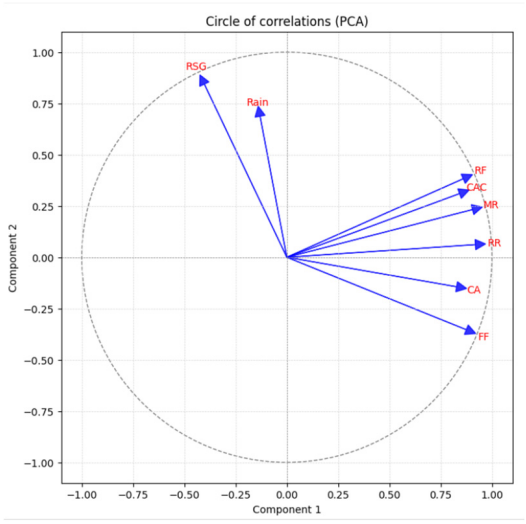
It is illustrated in Table 7, the Principal Component Analyses that were conducted are shown with the percentage of explained variance that they account for. It is evident that for the three target variables examined, the percentage of variance observed is highly comparable for both two- and three-component models. However, an increase in variance is observed when transitioning from two to three components, thereby introducing greater complexity to the model.

Table 7. Comparative summary of PCA analyses for each target variable.

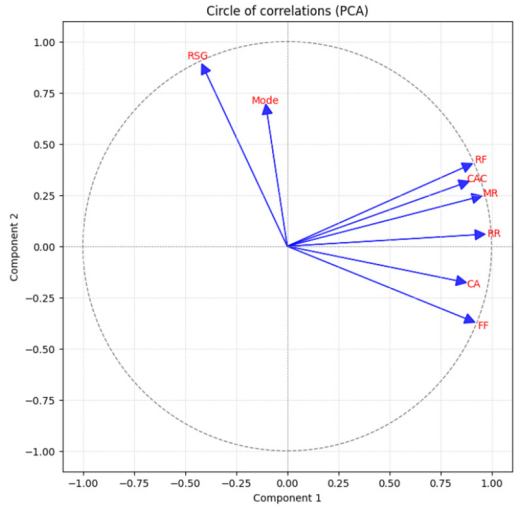
Target Variable	Components	% of Variance Explained
Rainfall intensity	2	74%
Rainfall intensity mode	2	71%
Maximum rainfall intensity value	2	75%
Rainfall intensity	3	81%
Rainfall intensity mode	3	80%
Maximum rainfall intensity value	3	83%

The correlation circles are displayed in Figure 5. Evidence suggests a strong correlation between the RSG variable and the components. Furthermore, the angle between the three target variables and the RSG variable is found to be minimal, indicating a high degree of correlation between them. RSG can be used as a predictor to estimate the target variable.

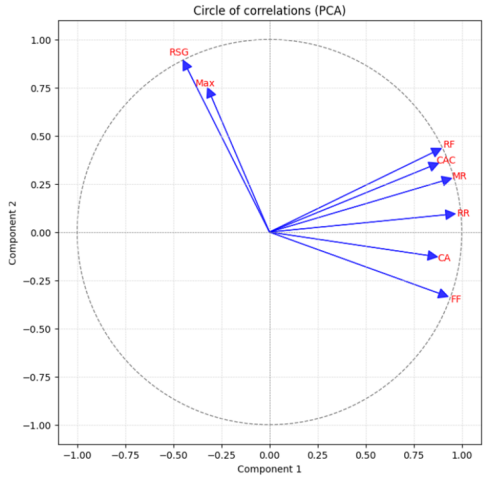
Following a comprehensive evaluation of the geometric factors, it was determined that only the RSG shape descriptor (perimeter/diameter) demonstrated a positive and statistically significant linear association with the three rainfall-intensity metrics (maximum, mean, and mode). The respective R^2 values were determined to be 0.52, 0.40, and 0.34, indicating a strong correlation between the RSG shape descriptor and the rainfall intensity metrics. RSG has been identified as a valuable predictor for early-warning models of extreme rainfall, with the potential to enhance hydrometeorological risk management (Table 8).



(**a**)



(**b**)



(**c**)

Figure 5. Correlation circles corresponding to the mean, mode, and maximum rainfall intensity, respectively. (**a**) Mean rainfall intensity variable for each pixel. (**b**) Rainfall intensity mode in each cloud system. (**c**) Maximum rainfall intensity in the cloud system.

Table 8. R^2 from cloud systems with rainfall rates greater than 50 mm/h and considering images larger than 20 pixels.

Dataset	Predictor	R^2
Max	RR	0.00
Max	CAC	0.01
Max	RSG	0.34
Max	FF	0.10
Max	RF	0.03
Max	MR	0.00
Max	CA	0.04
Mode	RR	0.01
Mode	CAC	0.01
Mode	RSG	0.40
Mode	FF	0.13
Mode	RF	0.02
Mode	MR	0.00
Mode	CA	0.04
Rain (mean)	RR	0.05
Rain (mean)	CAC	0.00
Rain (mean)	RSG	0.53
Rain (mean)	FF	0.24
Rain (mean)	RF	0.00
Rain (mean)	MR	0.01
Rain (mean)	CA	0.11

5. Discussion

From a physical perspective, the configuration of a tropical cyclone is indicative of the dynamic interplay between centrifugal forces, pressure gradients, and latent convection. The presence of an annular structure, for instance, has been linked to a more stable and efficient precipitation regime, characterized by the concentration of precipitation within an eye-wall ring [27]. In contrast, more elongated structures exhibiting multiple bands are indicative of less organized and more dispersed convection [28]. These configurations have a direct impact on rainfall distribution, both in terms of intensity and geographical extent. Research conducted by [1,2] utilized spatial metrics and satellite segmentation to establish a correlation between geometric shapes and precipitation clusters. The study proposed a hydrometeorological regionalization framework that is based on cyclonic geometry. The findings of the present study demonstrate a correlation between precipitation intensity and the geometric configuration of the rain system. It is evident that, while this was not explicitly obtained by [5], it does contribute an additional innovative component to Dvorak's shapes.

RSG is a strong predictor of rainfall intensity. However, no direct correlation emerges between intensity and the initial factors examined, indicating that cloud-shape descriptors capture organizational features not represented by those variables. Specifically, an RSG descriptor based on cloud morphology was identified, which shows a positive correlation with the maximum, average, and mode values of rainfall intensity. This finding suggests that the RSG descriptor can be a useful tool in early prediction models, especially for anticipating extreme rainfall events. Consequently, this approach has the potential to improve the effectiveness of early warning systems, thus facilitating more effective management of the risks associated with intense meteorological phenomena.

While the conventional approach to the Dvorak technique has centred on the estimation of wind intensity, the advent of high-resolution satellite data, such as that provided

by passive microwave sensors or polar orbiting precipitation radars, has facilitated a reinterpretation of the method from a hydrological perspective. Velden et al. [4] and later Ahmed et al. [9] emphasize that advancements in remote sensing can be combined with Dvorak patterns to deduce precipitation rates using geometric proxies, such as the radius of symmetry, eye definition, or convective band width. This contributes to the enhancement of the robustness of impact estimates and the improvement of early warning models for extreme events.

Recent Developments and Future Prospects

The evolution of deep learning algorithms and automated satellite image analysis has prompted research exploring the potential enhancement of the Dvorak technique through artificial intelligence. Yang et al. [29] proposed a neural network-based model for estimating the intensity of tropical cyclones, obtaining promising results that exceed the accuracy of the traditional methodology. These advances suggest that, while the Dvorak technique remains a useful tool, its future application could be complemented or even replaced by more accurate and automatic methods. The integration of data from diverse sources, including microwave sensors and satellite radars, has the potential to enhance the accuracy of tropical cyclone intensity estimation and mitigate the biases observed in the current methodology.

6. Conclusions

The Dvorak technique has been a fundamental methodology for estimating the intensity of tropical cyclones since its development in the 1970s [2]. While it has been demonstrated to be reliable and remains in extensive use, its deficiencies in accurately gauging the intensity of extreme storms have prompted the investigation of novel methodologies founded on emergent technologies. Recent studies suggest that artificial intelligence and multispectral data analysis could overcome the shortcomings of traditional methodology, offering more accurate and consistent estimates. However, until the validation and operationalisation of these new technologies is complete, the Dvorak technique will continue to play a crucial role in tropical meteorology, especially in regions where resources for direct observation are limited. The integration of the Dvorak technique with novel tools has the potential to transform tropical cyclone monitoring, enhancing the capacity to respond to these extreme events.

The study of the geometric shape of tropical cyclones, within the framework of the Dvorak method, is an area of research with profound theoretical and practical implications. Geometry is not just a visual attribute; rather, it is an observable manifestation of underlying dynamic processes that govern convective organisation and, consequently, the distribution and intensity of precipitation. The historical evolution of the method, from its empirical formulation to its versions assisted by artificial intelligence, reflects the scientific community's ongoing effort to translate visual information into reliable quantitative predictions. The present paper demonstrated a relationship between the geometry of cyclones and the intensity of precipitation. It also explored the usefulness of Dvorak patterns as a morphodynamic analysis tool. The aim of this exploration was to advance understanding of the physical structure of tropical cyclones and their destructive capacity.

We demonstrate that the explainable geometry of precipitating systems provides useful information about rainfall intensity in tropical cyclones. The perimeter-to-diameter ratio (PDR) and related descriptors capture a physical notion of compactness that correlates with mean, modal, and maximum rainfall, complementing wind-centered estimators. Due to their low computational cost and physical clarity, these descriptors are natural candidates for integration into operational nowcasting workflows and to support early

warning decisions. Future work should therefore include the following: (i) validation of the approach across multiple basins and seasons, (ii) standardisation of thresholds in physical units (km) and adaptive segmentation, (iii) merging with environmental and orographic predictors, and (iv) evaluation of real-time coupling with operational real-time storm tracking tools.

Author Contributions: Ivan Gonzalez Garcia and Alfonso Gutierrez-Lopez designed the model and the computational framework. Ivan Gonzalez Garcia, Ana Marcela Herrera Navarro and Hugo Jimenez-Hernandez analyzed the data, carried out the implementation and performed the calculations. Alfonso Gutierrez-Lopez wrote the manuscript with input from all authors. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Data are available from the corresponding author, upon reasonable request.

Acknowledgments: The authors are grateful to Autonomous University of Queretaro. The authors acknowledge Jose Alejandro Vargas Diaz, whose leadership and support inspired the accomplishment of this research.

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

Appendix A

Table A1 summarizes the cross-tests between five window sizes (number of pixels: 5, 10, 20, 50) and four rainfall-intensity thresholds (30, 40, 50, 60 mm/h). Each cell reports the number of detected objects for that combination. For example, at 50 mm/h and 20 pixels we obtained 2090 records (the dataset used in the main analysis). In general, lower thresholds or smaller windows yield more detections, and vice versa.

Table A1. Number of detected objects by rainfall intensity and window size.

Rainfall Intensity (mm/h)	5 Pixel	10 Pixel	20 Pixel	50 Pixel
30	3893	2923	2256	1519
40	3491	2687	2101	1451
50	3419	2654	2090	1460
60	3279	2540	1968	1387
70	3164	2441	1915	1369

Subsequently, we report the explained-variance levels obtained in the sensitivity analysis for two principal components. For each processing configuration we also provide the explained variance of a 2D PCA, by target metric (Rain/Mode/Max).

Table A2. Percentage of explained variance (2-component PCA) for Rain, Mode, and Max by rainfall intensity (mm/h) and window size (px).

mm/h	Rain (Mean)				Mode				Max			
	5 px	10 px	20 px	50 px	5 px	10 px	20 px	50 px	5 px	10 px	20 px	50 px
30	77.40	79.61	80.08	78.94	76.08	78.47	79.13	78.22	78.01	80.64	81.40	80.51
40	77.76	79.73	79.7	78.55	76.42	78.63	78.89	77.99	78.44	80.80	81.10	80.19
50	77.44	79.29	79.60	78.11	76.28	78.40	78.93	77.71	78.24	80.53	81.13	79.91
60	77.35	78.98	79.20	78.32	76.24	78.20	78.67	77.99	77.96	79.99	80.48	79.73
70	77.09	78.76	79.01	78.27	76.15	78.14	78.62	78.16	77.73	79.74	80.21	79.57

In this analysis, we use the mean of each block (Rain, Mode, and Max) as the reference value, and deviations are measured with respect to this central point.

- Rain (mean 78.65): the most stable metric, with a deviation range [−1.56, +1.43]; standard deviation ≈ 0.88; 100% of the values fall within ±2.
- Mode (mean 77.78): range [−1.70, +2.09]; standard deviation ≈ 1.07; 95% within ±2 and 100% within ±3.
- Max (mean 79.90): range [−2.17, +1.50]; standard deviation ≈ 1.10; 95% within ±2 and 100% within ±3.

The results indicate a low and controlled variability across the three metrics analyzed. All values lie within ±3 units of the mean, and at least 95% fall within ±2. This behavior reflects a good statistical stability, where the slight deviations observed in Mode and Max do not represent a significant compromise to the overall consistency of the data. As shown in Table 8, the number of images processed for classification depends on rainfall intensity and shape size. Figure 1 shows a case with a rainfall intensity of 50 mm/h and a shape size greater than 20 pixels.

Table A3. Dataset preview: 2090 records and 8 variables. Includes shape descriptors and the target variable Rain (mm/h). Corresponding to a rainfall intensity of 50 mm/h and a shape size greater than 20 pixels.

	RR	CAC	RSG	FF	RF	MR	CA	Rain (Mean)
1	0.065207	0.616131	1.152256	0.30147	0.40026	0.783499	0.768332	522.371316
2	0.168134	0.51211	0.926109	0.331562	0.284373	0.790743	0.694915	66.610856
3	0.072836	0.544925	0.613198	0.428816	0.16124	0.711123	0.828571	71.07168
4	0.189269	0.524034	0.710681	0.581251	0.293571	0.766087	0.898999	77.886964
5	0.45881	0.605061	0.811115	0.675506	0.444421	0.834784	0.885496	108.083906
	...	...					...	...
2086	0.239925	0.509584	0.816662	0.545794	0.36401	0.780322	0.812057	103.593554
2087	0.509364	0.677834	0.705976	1.2428	0.619414	0.897059	0.947368	76.053625
2088	0.361507	0.627395	1.146804	0.340765	0.44816	0.853739	0.746207	97.244481
2089	0.143326	0.524079	1.105967	0.396274	0.484708	0.795356	0.779934	198.149218
2090	0.292364	0.594964	0.94791	0.519156	0.466479	0.8156	0.808594	107.562615

Appendix B

Algorithm AnalysisRainGOES13

//Algorithm for processing rainfall intensity data and performing PCA and k-means. The rainfall_April.csv database contains image segmentation from 22 October 2015, at 12:15 a.m. to 24 October 2015, at 8:15 p.m. During this period, the hurricane went from Category I to Category V and then back to Category I.

CONTEXT OF THE PROBLEM

i. This analysis corresponds to the segmentation of GOES-13 satellite images covering the period from 22 October 2015 (00:15 hrs) to 24 October 2015 (20:15 hrs). During this period, the hurricane under study went from Category I to Category V
ii. and then back to Category I.
Image dimensions: 817 × 1280 pixels.
iii.

INPUT: Set of CSV files (file1, file2, . . ., file133), pixels, rain
OUTPUT: Final classification using k-means based on principal components and shape descriptors. Component projection graphs, correlation circle, and generated clusters.

STEPS:

1. Data loading
   - 1.1. Read all CSV files containing rainfall intensity information (each cell is a pixel).
   - 1.2. Store the data in a structure (e.g., list of DataFrames or multidimensional array).
2. Define precipitation threshold
   - 2.1. For each CSV file:
     - 2.1.1. Apply a filter to retain only those pixels with rainfall intensity > rain mm/h.
     - 2.1.2. Generate a new file or data structure with precipitation above that threshold
3. Image segmentation
   - 3.1. On the resulting heavy precipitation file:
   - 3.2. Identify continuous regions of rainfall.
   - 3.3. Calculate the area (in number of pixels) of each region.
   - 3.4. Filter and keep only regions with an area > pixels.
4. Extraction of statistics and descriptors
   - 4.1. For each region identified in each filtered file:
   - 4.2. Calculate the following statistics: Area, ConvexArea, Perimeter, maximum radius, minimum radius, average rainfall intensity in each shape, mode of each shape, maximum of each shape, median, standard deviation, and variance of each shape.
   - 4.3. From these statistics, calculate the shape and convexity descriptors: MR, RR, CAC, RSG, FF, RF, CA
5. Preparation of data for PCA
   - 5.1. Combine the information from all files (regions and descriptors) into a single dataset.
   - 5.2. Ensure that each row (observation) contains:
   - 5.3. Variables (descriptors) [MR, RR, CAC, RSG, FF, RF, CA]
   - 5.4. Rainfall intensity
   - 5.5. Also additional statistics (mode, maximum, mean) depending on the analysis required.
   - 5.6. Normalize the variables.
6. Application of PCA
   - 6.1. Perform six PCA processes:
   - 6.2. Two and three main components in each analysis.
   - 6.3. Vary the variables considered (e.g., average variables, mode, maximum value, etc.).
   - 6.4. Obtain the loadings for each variable and the scores for each observation.
7. Classification with k-means
   - 7.1. For each of the PCA results (scores with 2 or 3 components):
   - 7.2. Apply the k-means algorithm to group the observations.
   - 7.3. Determine the optimal number of groups (k) according to the Elbow Method criterion.
8. Generating results and visualizations
   - 8.1. Plot the projections of the principal components (2D or 3D) colored by the k-means clusters.

8.2. Generate the correlation circle to interpret the contribution of each variable to the principal components.
8.3. Display tables or graphs illustrating the classification obtained and the relationship with rainfall intensity.
8.4. Interpret the results.

9. End of algorithm

References

1. Dvorak, V.F. *A Technique for the Analysis and Forecasting of Tropical Cyclone Intensities from Satellite Pictures*; NOAA technical memorandum NESS; NESDIS (National Environmental Satellite, Data, and Information Service): Suitland, Maryland, 1973.
2. Dvorak, V.F. Tropical Cyclone Intensity Analysis and Forecasting from Satellite Imagery. *Mon. Weather. Rev.* **1975**, *103*, 420–430. [CrossRef]
3. Dvorak, V.F. *Tropical Cyclone Intensity Analysis Using Satellite Data*; US Department of Commerce, National Oceanic and Atmospheric Administration, National Environmental Satellite, Data, and Information Service: Silver Spring, Maryland, 1984.
4. Velden, C.S.; Harper, B.; Wells, F.C.; Beven, J.L.; Zehr, R.; Olander, T.L.; Mayfield, M.; Lander, M.A.; Edson, R.T.; Avila, L.A.; et al. The Dvorak Tropical Cyclone Intensity Estimation Technique: A Satellite-Based Method That Has Endured for over 30 Years. *Bull. Am. Meteorol. Soc.* **2006**, *87*, 1195–1210, Supplement in *Bull. Am. Meteorol. Soc.* **2006**, *87*, S6–S9. https://doi.org/10.1175/bams-87-9-velden. [CrossRef]
5. Zhou, Y.; Matyas, C.J. Regionalization of Precipitation Associated with Tropical Cyclones Using Spatial Metrics and Satellite Precipitation. *GIScience Remote Sens.* **2021**, *58*, 542–561. [CrossRef]
6. Houze, R.A. Mesoscale Convective Systems. *Rev. Geophys.* **2004**, *42*, 1–43. [CrossRef]
7. Schiesser, H.H.; Houze, R.A.; Huntrieser, H. The Mesoscale Structure of Severe Precipitation Systems in Switzerland. *Mon. Weather. Rev.* **1995**, *123*, 2070–2097. [CrossRef]
8. Velden, C.S.; Olander, T.L.; Zehr, R.M. Development of an Objective Scheme to Estimate Tropical Cyclone Intensity from Digital Geostationary Satellite Infrared Imagery. *Weather. Forecast.* **1998**, *13*, 172–186. [CrossRef]
9. Ahmed, R.; Mohapatra, M.; Giri, R.K.; Dwivedi, S. An Evaluation of the Advanced Dvorak Technique (9.0) for the Topical Cyclones over the North Indian Ocean. *Trop. Cyclone Res. Rev.* **2021**, *10*, 201–208. [CrossRef]
10. Kossin, J.P.; Emanuel, K.A.; Vecchi, G.A. The Poleward Migration of the Location of Tropical Cyclone Maximum Intensity. *Nature* **2014**, *509*, 349–352. [CrossRef]
11. Kawabata, Y.; Shimada, U.; Yamaguchi, M. The 30-Year (1987–2016) Trend of Strong Typhoons and Genesis Locations Found in the Japan Meteorological Agency's Dvorak Reanalysis Data. Kisho shushi. *J. Meteorol. Soc. Jpn.* **2023**, *101*, 435–443. [CrossRef]
12. Brown, D.; Franklin, J. Dvorak Tropical Cyclone Wind Speed Biases Determined from Reconnaissance-Based "Best Track" Data (1997–2003). In Proceedings of the 26th Conference on Hurricanes and Tropical Meteorology, Miami, FL, USA, 3–7 May 2004.
13. Sangster, S.J.; Landsea, C.W. Constraints in Dvorak Wind Speed Estimates: How Quickly Can Hurricanes Intensify? *Weather Forecast.* **2020**, *35*, 1235–1241. [CrossRef]
14. Nakazawa, T.; Hoshino, S. Intercomparison of Dvorak Parameters in the Tropical Cyclone Datasets over the Western North Pacific. *Sola* **2009**, *5*, 33–36. [CrossRef]
15. Zick, S.E. Anatomy of a Storm: A Review of Shape Analysis Research That Fuses Form and Function in Weather Forecasting and Analysis. *Prog. Phys. Geogr. Earth Environ.* **2022**, *47*, 152–170. [CrossRef]
16. Aguilar, J. *Severidad por Intensidad de Tormenta Asociada a su Evolución Geométrica Utilizando Redes Neuronales Artificiales*; Universidad Autónoma de Querétaro, Facultad de Ingeniería: Santiago de Querétaro, Mexico, 2019. Available online: https://ring.uaq.mx/handle/123456789/1762?mode=full (accessed on 23 May 2025).
17. Servicio Meteorológico Nacional. Portal Oficial del Servicio Meteorológico Nacional. 2024. Available online: https://smn.conagua.gob.mx/es/ (accessed on 23 May 2025).
18. Gutierrez-Lopez, A. Methodological Guide to Forensic Hydrology. *Water* **2022**, *14*, 3863. [CrossRef]
19. Meza-Ruiz, M.; Gutierrez-Lopez, A. Goes-13 IR Images for Rainfall Forecasting in Hurricane Storms. *Forecasting* **2020**, *2*, 85–101. [CrossRef]
20. Cox, E.P. A Method of Assigning Numerical and Percentage Values to the Degree of Roundness of Sand Grains. *J. Paleontol.* **1927**, *1*, 179–183.
21. Pentland, A. A method of measuring the angularity of sands. *Acta Eng. Dom. Trans. R. Soc. Can.* **1927**, *21*.
22. Ritter, N.; Cooper, J. New Resolution Independent Measures of Circularity. *J. Math. Imaging Vis.* **2009**, *35*, 117–127. [CrossRef]
23. Zunic, J.; Rosin, P.L. A New Convexity Measure for Polygons. *IEEE Trans. Pattern Anal. Mach. Intell.* **2004**, *26*, 923–934. [CrossRef] [PubMed]

24. Yaglom, I.M.; Boltyanskii, V.G. *Convex Figures*; State Publishing House for Technical and Theoretical Literature: Moscow, Russia, 1951. (In Russian)
25. Szasz, O.; Rosenthal, A. Eine Extremaleigenschaft Der Kurven Konstanter Breite. *Jahresber. Der Dtsch. Math. Ver.* **2025**, *25*, 278–282.
26. Kubara, M. Katarzyna Kopczewska Akaike Information Criterion in Choosing the Optimal K-Nearest Neighbours of the Spatial Weight Matrix. *Spat. Econ. Anal.* **2023**, *19*, 73–91. [CrossRef]
27. Ryu, S.; Hong, S.-E.; Park, J.-D.; Hong, S. An Improved Conversion Relationship between Tropical Cyclone Intensity Index and Maximum Wind Speed for the Advanced Dvorak Technique in the Northwestern Pacific Ocean Using SMAP Data. *Remote Sens.* **2020**, *12*, 2580. [CrossRef]
28. Rodgers, E.; Gentry, R.C.; Shenk, W.; Oliver, V. The Benefits of Using Short-Interval Satellite Images to Derive Winds for Tropical Cyclones. *Mon. Weather. Rev.* **1979**, *107*, 575–584. [CrossRef]
29. Yang, W.; Fei, J.; Huang, X.; Ding, J.; Cheng, X. Enhancing Tropical Cyclone Intensity Estimation from Satellite Imagery through Deep Learning Techniques. *J. Meteorol. Res.* **2024**, *38*, 652–663. [CrossRef]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Bibliografía

Aguilar, J. (2019). *Severidad por intensidad de tormenta asociada a su evolución geométrica utilizando redes neuronales artificiales* [Tesis, Universidad Autónoma de Querétaro, Facultad de Ingeniería]. https://ri-ng.uaq.mx/handle/123456789/1762

Ahmed, R., Mohapatra, M., Giri, R. K., & Dwivedi, S. (2021). An Evaluation of the Advanced Dvorak Technique (9.0) for the Topical Cyclones over the North Indian Ocean. *Trop. Cyclone Res. Rev.*, *10*, 201–208.

Al Mawali, B., Ibrahim, A., Al Yahyai, S., & Ali, I. (2025). The Reliability of Satellite Precipitation Estimates during Tropical Cyclone Shaheen. *Sci. Rep.*, *15*, 33769. https://doi.org/10.1038/s41598-025-00362-2

Balázs, P., & Brunetti, S. (2020). A Measure of Q-Convexity for Shape Analysis. *Journal of Mathematical Imaging and Vision*.

Ban, Y., & Lee, S. (2020). Protuberance of Depth: Detecting Interest Points from a Depth Image. *Computer Vision and Image Understanding*.

Brown, D., & Franklin, J. (2004). Dvorak Tropical Cyclone Wind Speed Biases Determined from Reconnaissance-Based "Best Track" Data (1997–2003). En *Proceedings of the 26th Conference on Hurricanes and Tropical Meteorology*. Miami, FL, Estados Unidos.

Cattani, E., Merino, A., Guijarro, J. A., & Levizzani, V. (2018). East Africa Rainfall Trends and Variability 1983–2015 Using Three Long-Term Satellite Products. *Remote Sens.*, *10*, 931. https://doi.org/10.3390/rs10060931

Chakerian, G. D., & Groemer, H. (1983). Convex Bodies of Constant Width. En P. M. Gruber y J. M. Wills (Eds.), *Convexity and Its Applications* (pp. 49–96). Birkhäuser.

Chávez, G. M., Villa, J., Sarocchi, D., & González-Ramírez, E. (2020). A Method and Software Solution for Classifying Clast Roundness Based on the Radon Transform. *Computers & Geosciences*.

Chittaranjan Sahay, S., & Ghose, S. (2020). Effect of Filter Type and Filter Size on Roundness/Circularity Measurement Using Different Mathematical Algorithms. En *Proceedings of the International Mechanical Engineering Congress and Exposition*.

Cox, E. P. (1927). A Method of Assigning Numerical and Percentage Values to the Degree of Roundness of Sand Grains. *J. Paleontol.*, *1*, 179–183.

Dvorak, V. F. (1973). *A Technique for the Analysis and Forecasting of Tropical Cyclone Intensities from Satellite Pictures*. NOAA technical memorandum NESS; NESDIS (National Environmental Satellite, Data, and Information Service): Suitland, Maryland.

Dvorak, V. F. (1975). Tropical Cyclone Intensity Analysis and Forecasting from Satellite Imagery. *Mon. Weather. Rev.*, *103*, 420–430.

Dvorak, V. F. (1984). *Tropical Cyclone Intensity Analysis Using Satellite Data*. US Department of Commerce, National Oceanic and Atmospheric Administration, National Environmental Satellite, Data, and Information Service: Silver Spring, Maryland.

Estrada, F., Botzen, W. J. W., & Tol, R. S. J. (2015). Economic Losses from US Hurricanes Consistent with an Influence from Climate Change. *Nat. Geosci.*, *8*, 880–885.

Garcia, I. G., Gutierrez-Lopez, A., Herrera Navarro, A. M., & Jimenez-Hernandez, H. (2025). Hurricane Precipitation Intensity as a Function of Geometric Shape: The Evolution of Dvorak Geometries. *ISPRS Int. J. Geo-Inf.*, *14*, 443. https://doi.org/10.3390/ijgi14110443

Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4a ed.). Pearson.

Gutierrez, L. M. A., & Arellano, L. F. R. (2010). Estudio de tormentas tipo en la ciudad de Querétaro. *ciencia@uaq*, *3*, 62–79.

Gutierrez-Lopez, A. (2022). Methodological Guide to Forensic Hydrology. *Water*, *14*, 3863.

Hadwiger, H. (1975). *Vorlesungen über Inhalt, Oberfläche und Isoperimetrie*. Springer: Berlin, Germany.

Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A k-means clustering algorithm. *Applied Statistics*, *28*(1), 100–108.

Hobouchian, M. P. (2015). *Estimaciones de precipitación por satélite en el área subtropical de Sudamérica: análisis y validación*. Tesis de licenciatura, Universidad

de Buenos Aires, Argentina.

Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, *24*(6), 417–441.

Hou, A. Y., et al. (2014). The Global Precipitation Measurement Mission. *Bull. Am. Meteorol. Soc.*, *95*, 701–722.

Houze, R. A. (2004). Mesoscale Convective Systems. *Rev. Geophys.*, *42*, 1–43.

Huffman, G. J., Bolvin, D. T., Braithwaite, D., Hsu, K.-L., Joyce, R. J., Kidd, C., Nelkin, E. J., Sorooshian, S., Stocker, E. F., Tan, J., Wolff, D. B., & Xie, P. (2020). Integrated Multi-satellite Retrievals for the Global Precipitation Measurement (GPM) Mission (IMERG). En V. Levizzani, C. Kidd, D. B. Kirschbaum, C. D. Kummerow, K. Nakamura y F. J. Turk (Eds.), *Satellite Precipitation Measurement* (Advances in Global Change Research, Vol. 67, pp. 343–353). Springer. https://doi.org/10.1007/978-3-030-24568-9_19

Ilić, V., & Ralević, N. M. (2020). Hexagonality as a New Shape-Based Descriptor of Object. *Journal of Mathematical Imaging and Vision*.

Kawabata, Y., Shimada, U., & Yamaguchi, M. (2023). The 30-Year (1987–2016) Trend of Strong Typhoons and Genesis Locations Found in the Japan Meteorological Agency's Dvorak Reanalysis Data. Kisho shushi. *J. Meteorol. Soc. Jpn.*, *101*, 435–443.

Kossin, J. P., Emanuel, K. A., & Vecchi, G. A. (2014). The Poleward Migration of the Location of Tropical Cyclone Maximum Intensity. *Nature*, *509*, 349–352.

Kubara, M. (2023). Katarzyna Kopczewska Akaike Information Criterion in Choosing the Optimal K-Nearest Neighbours of the Spatial Weight Matrix. *Spat. Econ. Anal.*, *19*, 73–91.

Leutenegger, S., Chli, M., & Siegwart, R. Y. (2011). BRISK: Binary Robust Invariant Scalable Keypoints. En *Proceedings of the 2011 International Conference on Computer Vision* (pp. 2548–2555).

MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. En *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability* (Vol. 1, pp. 281–297). University of California Press.

Matheron, G. (1975). *Random Sets and Integral Geometry*. John Wiley & Sons: New York, NY, USA.

Meza, M., Curiel, L., González, D., & Álvarez, C. (2014). Imágenes satelitales y distribución espacial de la lluvia en el estado de Querétaro. Caso: Tormenta del 18

de agosto de 2014. *Nthe*, *14*, 21–29.

Meza-Ruiz, M., & Gutierrez-Lopez, A. (2020). Goes-13 IR Images for Rainfall Forecasting in Hurricane Storms. *Forecasting*, *2*, 85–101.

Minkowski, H. (1897). Allgemeine Lehrsätze über die konvexen Polyeder. *Nachrichten der Gesellschaft der Wissenschaften zu Göttingen*.

Nakazawa, T., & Hoshino, S. (2009). Intercomparison of Dvorak Parameters in the Tropical Cyclone Datasets over the Western North Pacific. *Sola*, *5*, 33–36.

Nguyen, T. N. (2020). A Projection-Based Method for Shape Measurement. *J. Math. Imaging Vis.*, *62*, 489–504.

Nguyen, V. D., Rouzegari, N., Dao, V., Almutlaq, F., Nguyen, P., & Sorooshian, S. (2025). Comparative Analysis of Satellite-Based Precipitation Products during Extreme Rainfall from Super Typhoon Yagi in Hanoi, Vietnam (September 2024). *Remote Sens.*, *17*, 1598. https://doi.org/10.3390/rs17091598

Pearson, K. (1901). On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, *2*(11), 559–572.

Peng, Z., & Liu, D. (2020). In-Process Measuring Method for the Size and Roundness of Workpiece with Discontinuous Surface in Cylindrical Grinding Process. *Measurement*.

Pentland, A. (1927). A method of measuring the angularity of sands. *Acta Eng. Dom. Trans. R. Soc. Can.*, *21*.

Ricciardulli, L., Howell, B., Jackson, C. R., Hawkins, J., Courtney, J., Stoffelen, A., Langlade, S., Fogarty, C., Mouche, A., Blackwell, W., et al. (2023). Remote Sensing and Analysis of Tropical Cyclones: Current and Emerging Satellite Sensors. *Trop. Cyclone Res. Rev.*, *12*, 267–293. https://doi.org/10.1016/j.tcrr.2023.12.003

Ritter, N., & Cooper, J. (2009). New Resolution Independent Measures of Circularity. *J. Math. Imaging Vis.*, *35*, 117–127.

Rodgers, E., Gentry, R. C., Shenk, W., & Oliver, V. (1979). The Benefits of Using Short-Interval Satellite Images to Derive Winds for Tropical Cyclones. *Mon. Weather. Rev.*, *107*, 575–584.

Ryu, S., Hong, S.-E., Park, J.-D., & Hong, S. (2020). An Improved Conversion Relationship between Tropical Cyclone Intensity Index and Maximum Wind Speed for the Advanced Dvorak Technique in the Northwestern Pacific Ocean Using

SMAP Data. *Remote Sens.*, *12*, 2580.

Sangster, S. J., & Landsea, C. W. (2020). Constraints in Dvorak Wind Speed Estimates: How Quickly Can Hurricanes Intensify? *Weather and Forecasting*, *35*, 1235–1241. https://doi.org/10.1175/WAF-D-19-0186.1

Schiesser, H. H., Houze, R. A., & Huntrieser, H. (1995). The Mesoscale Structure of Severe Precipitation Systems in Switzerland. *Mon. Weather. Rev.*, *123*, 2070–2097.

Serra, J. (1982). *Image Analysis and Mathematical Morphology*. Academic Press: London, UK.

Servicio Meteorológico Nacional. (2024). *Portal oficial del Servicio Meteorológico Nacional*. https://smn.conagua.gob.mx/es/

Shah, A., et al. (2021). Comparative Analysis of Feature Extraction and Fusion for Blind Authentication of Digital Images Using Chroma Channels. *Signal Processing: Image Communication*.

Stancu, A. (2006). The Floating Body Problem. *Bull. Lond. Math. Soc.*, *38*, 839–846.

Szasz, O., & Rosenthal, A. (2025). Eine Extremaleigenschaft Der Kurven Konstanter Breite. *Jahresber. Der Dtsch. Math. Ver.*, *25*, 278–282.

Tareen, S. A. K., & Saleem, Z. (2018). A Comparative Analysis of SIFT, SURF, KAZE, AKAZE, ORB, and BRISK. En *Proceedings of the 2018 International Conference on Computing, Mathematics and Engineering Technologies*. https://doi.org/10.1109/ICOMET.2018.8346440

Toponogov, V. A. (2006). *Differential Geometry of Curves and Surfaces: A Concise Guide*. Birkhäuser: Boston, MA, USA.

Valentine, F. A. (1964). *Convex Sets*. McGraw-Hill: New York, NY, USA.

Velden, C. S., Olander, T. L., & Zehr, R. M. (1998). Development of an Objective Scheme to Estimate Tropical Cyclone Intensity from Digital Geostationary Satellite Infrared Imagery. *Weather. Forecast.*, *13*, 172–186.

Velden, C. S., Harper, B., Wells, F. C., Beven, J. L., Zehr, R., Olander, T. L., Mayfield, M., Lander, M. A., Edson, R. T., Avila, L. A., et al. (2006). The Dvorak Tropical Cyclone Intensity Estimation Technique: A Satellite-Based Method That Has Endured for over 30 Years. *Bulletin of the American Meteorological Society*, *87*, 1195–1210 (suplemento: S6–S9). https://doi.org/10.1175/BAMS-87-9-1195

Velden, C., Knaff, J., Herndon, D., Mouche, A., Hawkins, J., Panegrossi, G., Stoffelen, A., Courtney, J., Tsukada, T., & Fontan, A.-C. (2025). Recent Innovations in

Satellite-Based Applications and Their Impacts on Tropical Cyclone Analyses and Forecasts. *J. Eur. Meteorol. Soc.*, *2*, 100011. https://doi.org/10.1016/j.jemets.2025.100011

Wang, D., Yan, Z., & Liu, P. (2025). Fine-Grained Interpretation of Remote Sensing Image: A Review. *Remote Sens.*, *17*, 3887. https://doi.org/10.3390/rs17233887

Wing, A. A., Emanuel, K., & Solomon, S. (2015). On the Factors Affecting Trends and Variability in Tropical Cyclone Potential Intensity. *Geophys. Res. Lett.*, *42*. https://doi.org/10.1002/2015GL066145

Yaglom, I. M., & Boltyanskii, V. G. (1951). *Convex Figures*. State Publishing House for Technical and Theoretical Literature. (En ruso)

Yang, W., Fei, J., Huang, X., Ding, J., & Cheng, X. (2024). Enhancing Tropical Cyclone Intensity Estimation from Satellite Imagery through Deep Learning Techniques. *J. Meteorol. Res.*, *38*, 652–663.

Yang, N., Wang, C., & Li, X. (2024). Improving Tropical Cyclone Precipitation Forecasting With Deep Learning and Satellite Image Sequencing. *J. Geophys. Res. Mach. Learn. Comput.*, *1*, e2024JH000175.

Zhou, Y., & Matyas, C. J. (2021). Regionalization of Precipitation Associated with Tropical Cyclones Using Spatial Metrics and Satellite Precipitation. *GIScience Remote Sens.*, *58*, 542–561.

Zick, S. E. (2022). Anatomy of a Storm: A Review of Shape Analysis Research That Fuses Form and Function in Weather Forecasting and Analysis. *Prog. Phys. Geogr. Earth Environ.*, *47*, 152–170.

Zunic, J., & Rosin, P. L. (2004). A New Convexity Measure for Polygons. *IEEE Trans. Pattern Anal. Mach. Intell.*, *26*, 923–934.