

UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingenieros en Topografía,  
Geodesia y Cartografía

Caracterización del fenómeno de islas de calor urbano en una ciudad  
tropical andina colombiana (Cartago, Valle del Cauca)  
integrando variables ambientales

**TESIS DOCTORAL**

Autor

**Julián Garzón Barrero**

Máster Universitario en Sistemas de Información Geográfica

2023



Departamento de Ingeniería Topográfica y Cartografía  
Escuela Técnica Superior de Ingenieros en Topografía, Geodesia  
y Cartografía

**Tesis doctoral**

Caracterización del fenómeno de islas de calor urbano en una ciudad tropical  
andina colombiana (Cartago, Valle del Cauca) integrando variables  
ambientales

**Autor:** Julián Garzón Barrero  
Máster Universitario en Sistemas de Información Geográfica

**Directores**

Prof. Iñigo Molina Sánchez  
Doctor por la Universidad Politécnica de Madrid

Prof. Jesús Velasco Gómez  
Doctor por la Universidad Politécnica de Madrid

2023



**Título de la tesis:** Caracterización del fenómeno de islas de calor urbano en una ciudad tropical andina colombiana (Cartago, Valle del Cauca) integrando variables ambientales

**Autor:** Julián Garzón Barrero

Tribunal nombrado por el Excmo. y Magfco. Sr. Rector de la Universidad Politécnica de Madrid, el día ..... de.....de 2023.

Presidente/a: \_\_\_\_\_

Vocal: \_\_\_\_\_

Vocal: \_\_\_\_\_

Vocal: \_\_\_\_\_

Secretario/a: \_\_\_\_\_

Suplente: \_\_\_\_\_

Suplente: \_\_\_\_\_

Realizado el acto de defensa y lectura de Tesis el día..... de.....de 2023 en la ETSI en Topografía, Geodesia y Cartografía.

CALIFICACIÓN:

EL/LA PRESIDENTE/A

LOS/LAS VOCALES

EL/LA SECRETARIO/A

# Resumen

La dinámica urbana y sus impactos asociados han llevado a modificaciones significativas en la estructura básica y el funcionamiento de los ecosistemas. La heterogeneidad del paisaje juega un papel importante en la variación de la temperatura superficial terrestre (LST) dentro de la ciudad y sus áreas circundantes. Las islas de calor urbanas superficiales (SUHI) son una alteración antropogénica del sistema terrestre. Sus patrones espaciotemporales generan variaciones térmicas que afectan la relación entre los sistemas urbano y biofísico. Comprender el efecto de estos cambios es fundamental para enfrentar los desafíos que genera el crecimiento de las poblaciones urbanas. En esta Tesis Doctoral se utilizaron 37 imágenes de los sensores Landsat-TM, ETM+, OLI/TIRS y 11 imágenes del instrumento multiespectral Sentinel-2 (S2-MSI) para derivar LST y diferentes factores ambientales que permitieron generar un modelo explicativo del fenómeno SUHI, detectando patrones térmicos espaciotemporales a través de la combinación de técnicas de análisis de componentes principales (PCA), y regresión lineal múltiple (MLR) para la ciudad colombiana de Cartago durante el período 2001-2020. Las variables del modelo incluyeron distintos índices espectrales, transformadas espectrales y factores de proximidad. Para estimar los valores LST en las imágenes Landsat-8 OLI/TIRS se probaron 3 modelos de emisividad. El modelo de fracción de cobertura vegetal ( $F_{COVER}$ ) derivado de S2-MSI produjo los mejores resultados para recuperar LST con  $R^2 = 0,78$  y errores medios comprendidos entre 1,1 y 1,3 °C, en comparación con las temperaturas medidas *in situ*. Los resultados indicaron que los factores ambientales con mayor impacto fueron los índices de diferencia normalizada de agua (NDWI), 52%, y de construcción (NDBI), 21%. El resto de factores incidieron en menor medida. Además, durante la serie temporal 2001-2020 se observó un aumento continuo térmico en tiempo y espacio. Esta investigación propone un modelo novedoso para determinar el fenómeno SUHI, incorporando el algoritmo *Weighted Naïve Bayes* (WNB) que permitió identificar áreas propensas a temperaturas extremas. El modelo obtenido con WNB demostró confiabilidad de 95%, frente al 88% proporcionado por el algoritmo *Support Vector Machine* (SVM). El algoritmo WNB permitió integrar de manera eficiente la contribución de cada factor ambiental involucrado. La segmentación se utilizó para producir el mapa de recomendación térmica urbana y categorizar el entorno con un estado SUHI específico y, por tanto, proponer acciones de mitigación y adaptación como parte del proceso de planificación urbana.

# Abstract

Urban dynamics and its associated impacts have led to significant changes in the basic structure and functioning of ecosystems. Landscape heterogeneity plays an important role in the variation of the land surface temperature (LST) within the city and its surrounding areas. Surface Urban Heat Islands (SUHI) are an anthropogenic disturbance of the Earth system. Its spatiotemporal patterns generate thermal variations that affect the relationship between urban and biophysical systems. Understanding the effect of these changes is essential to face the challenges generated by the growth of urban populations. In this Doctoral Thesis, 37 images from Landsat-TM, ETM+, OLI/TIRS sensors and 11 images from the Sentinel-2 multispectral instrument (S2-MSI) were used to derive LST and different environmental factors that allowed generating an explanatory model of the SUHI phenomenon, detecting spatiotemporal thermal patterns through the combination of principal component analysis (PCA) techniques and multiple linear regression (MLR) for the Colombian city of Cartago during the period 2001-2020. The model variables included different spectral indices, spectral transforms, and proximity factors. To estimate the LST values on the Landsat-8 OLI/TIRS images, 3 emissivity models were tested. The fractional vegetation cover ( $F_{COVER}$ ) model derived from S2-MSI produced the best results for recovering LST with  $R^2 = 0.78$  and mean errors between 1.1 and 1.3 °C, compared to the temperatures measured in situ. The results indicated that the environmental factors with the greatest impact were the Normalized Difference Water Index (NDWI), 52%, and the Normalized Difference Building Index (NDBI), 21%. The rest of the factors are affected to a lesser extent. Furthermore, during the 2001-2020 time series, a continuous thermal increase was observed in time and space. This research proposes a novel model to determine the SUHI phenomenon, incorporating the Weighted Naïve Bayes (WNB) algorithm, which allowed the identification of areas prone to extreme temperatures. The model obtained with WNB demonstrated reliability of 95%, compared to 88% provided by the Support Vector Machine (SVM) algorithm. The WNB algorithm allowed to efficiently integrate the contribution of each environmental factor involved. The segmentation obtained was used to categorize the urban environment according to a specific SUHI status and, therefore, propose mitigation and adaptation actions as part of the urban planning process.

# Agradecimientos

Esta disertación está lejos de ser un esfuerzo individual, y no tendría un espíritu valedero sin reconocer el soporte de quienes lo influenciaron, motivaron y guiaron. Dicho esto, me gustaría presentar mis agradecimientos a quienes contribuyeron en mi desarrollo personal y científico durante los últimos años.

Gracias a Dios por bendecir mi vida entera.

Ofrezco mi más sincera gratitud a mi director de tesis y amigo, el Profesor Doctor Iñigo Molina Sánchez, por brindarme la oportunidad de obtener un título de doctorado de la Universidad Politécnica de Madrid. Por enseñarme como investigar en el campo de la teledetección. Siempre conté con su orientación analítica, apoyo, paciencia y comentarios útiles con los más altos estándares para construir la estructura de esta investigación y garantizar su calidad académica. Bajo su enfoque siempre científico, obtuvimos la publicación de un artículo derivado de esta Tesis Doctoral en una de las revistas más prestigiosas del mundo. Espero que podamos continuar avanzando hacia la construcción del conocimiento, investigando juntos en el futuro y poderle retornar algo de lo que toda su bondad ha hecho en mí.

Por su puesto que también ofrezco mi gratitud al Profesor Doctor Jesús Velasco, quien aparte de ser mi director de tesis, permitió que este camino iniciara desde una de sus visitas a mi universidad de origen en Colombia, planteando caminos de trabajo conjunto, siendo generoso en su conocimiento y abriendo las rutas administrativas para lograr convenios interuniversitarios.

También, he tenido la fortuna de contar con el apoyo afectuoso y empático de 4 mujeres que rodean mi vida y forman mi núcleo familiar básico. Simplemente confiaron en mí. Me apoyaron con sus estilos muy particulares, siempre atentas, brindándome su infinito amor en momentos naturalmente complejos, apenas justos en un proceso de formación doctoral.

# ÍNDICE GENERAL

<b>Resumen</b> .....	<b>i</b>
<b>Abstract</b> .....	<b>ii</b>
<b>Agradecimientos</b> .....	<b>iii</b>
<b>Listado de figuras</b> .....	<b>vii</b>
Listado de figuras en apéndices .....	ix
<b>Listado de tablas</b> .....	<b>x</b>
Listado de tablas en apéndices .....	x
<b>Listado de abreviaturas</b> .....	<b>xi</b>

## CAPÍTULO 1

<b>INTRODUCCIÓN Y PLANTEAMIENTO GENERAL DEL PROBLEMA</b> .....	<b>1</b>
1.1 Contexto generalizado .....	2
1.2 El problema.....	6
1.3 Motivación .....	9
1.4 Objetivos de la investigación .....	10
1.4.1 Objetivo principal.....	10
1.4.2 Objetivos específicos .....	10
1.5 Descripción del contenido de la tesis.....	11

## CAPÍTULO 2

<b>ANTECEDENTES TEÓRICOS</b> .....	<b>12</b>
2.1 Estado del arte.....	13
2.1.1 Climatología urbana .....	21
2.1.2 Plataformas satelitales empleadas para estimar LST .....	25
2.1.3 Escalas para analizar SUHI.....	28
2.1.4 Técnicas para la estimación del fenómeno .....	30
2.1.5 Factores influenciadores .....	32
2.2 Interacción de la radiación con la atmósfera y la superficie terrestre .....	35
2.3 Estimación de LST desde sensores remotos .....	40
2.3.1 Fuentes de datos para la obtención de LSE .....	45
2.4 Modelación de tendencias y contribución de factores asociados a LST .....	47
2.5 Algoritmos de aprendizaje automático (ML) .....	49
2.5.1 Support Vector Machine (SVM) .....	50
2.5.2 Weighted Naïve Bayes (WNB) .....	52

### **CAPÍTULO 3**

<b>ÁREA DE ESTUDIO Y MATERIALES .....</b>	<b>55</b>
3.1 Área de estudio .....	56
3.2 Materiales.....	57
3.2.1 Datos de sensores remotos.....	58
3.2.2 Termómetros portátiles ensamblados para contraste de LST.....	59

### **CAPÍTULO 4**

<b>PROPUESTA METODOLÓGICA .....</b>	<b>62</b>
4.1 Preprocesamiento de imágenes .....	63
4.2 Recuperación de la temperatura superficial terrestre (LST).....	64
4.3 Contraste de productos LST Landsat-8 OLI/TIRS y mediciones directas .....	69
4.4 Factores candidatos como determinantes de LST.....	71
4.5 Propuesta para la modelización del fenómeno .....	75

### **CAPÍTULO 5**

<b>RESULTADOS Y DISCUSIÓN DE LA MODELACIÓN SUHI.....</b>	<b>82</b>
5.1 Estimación de LST .....	83
5.2 Análisis de los componentes principales .....	87
5.3 Identificación de factores influenciadores de LST.....	95
5.3.1 Análisis de la modelación estadística MLR .....	100
5.4 Modelación SUHI .....	104
5.5 Perspectivas e implicaciones para la planificación urbana .....	111

### **CAPÍTULO 6**

<b>CONCLUSIONES .....</b>	<b>115</b>
6.1 Respuesta a objetivos específicos y preguntas de investigación .....	116
6.2 Contribuciones .....	120
6.3 Limitaciones y futuras líneas de investigación .....	122
6.4 Difusión de resultados .....	123

### **CAPÍTULO 7**

<b>BIBLIOGRAFÍA.....</b>	<b>125</b>
--------------------------	------------

<b>APÉNDICES.....</b>	<b>157</b>
Apéndice A. Listado de imágenes satelitales procesadas.....	157
Apéndice B. Procedimiento de verificación y ajuste de termómetros .....	160
Apéndice C. Código fuente regresión lineal múltiple.....	163
Apéndice D. Código fuente de implementación WNB.....	175

# Listado de figuras

Figura 1. Componentes de la ecuación de balance de energía superficial.....	17
Figura 2. Estudios UCMaP alrededor del mundo .....	23
Figura 3. Escalas empleadas en estudios térmicos. ....	29
Figura 4. Factores impulsores contribuyentes a la isla de calor urbano superficial .....	35
Figura 5. Influencia de la atmósfera en la medición de energía captada por el sensor.....	37
Figura 6. Características espectrales de la transmitancia atmosférica .....	40
Figura 7. Modelo de clasificación basado en SVM .....	51
Figura 8. Modelo de clasificación basado en WNB .....	54
Figura 9. Localización del área de estudio.....	56
Figura 10. Distribución temporal de las imágenes procesadas.....	59
Figura 11. Prototipo de termómetro empleado para mediciones directas de LST .....	60
Figura 12. Modelo para la recuperación y evaluación de LST .....	65
Figura 13. Acople L8 OLI/TIRS B10-S2 MSI para la obtención de mapas LST .....	67
Figura 14. Mediciones de campo con termómetros de portátiles.....	70
Figura 15. Ubicación de las mediciones LST in situ .....	71
Figura 16. Modelización para propuesta del fenómeno SUHI .....	77
Figura 17. Arquitectura de modelado WNB para generación del producto SUHI.....	80
Figura 18. Contraste modelos LSE en la recuperación de LST L8/TIRS B10.....	84
Figura 19. Ajuste entre medición directa y LST L8 con diferentes fuentes LSE.....	85
Figura 20. Comportamiento de LST media de imágenes procesadas 2001-2020 .....	86
Figura 21. Porción de varianza explicada por factores y componentes principales.....	87
Figura 22. Variabilidad térmica 2001–2020.....	88
Figura 23. Variabilidad NDVI.....	89
Figura 24. Variabilidad NDBI.....	90
Figura 25. Variabilidad NDWI .....	91
Figura 26. Variabilidad Tasseled Cap – Brillo (TCB).....	92

Figura 27. Variabilidad Tasseled Cap – Verdor (TCG) .....	92
Figura 28. Variabilidad Tasseled Cap – Humedad (TCW).....	93
Figura 29. Proximidad al centro urbano (PUC) .....	94
Figura 30. Proximidad a los cuerpos de agua (PW) .....	94
Figura 31. Diagrama de caja y bigotes. Factores evaluados a través de PCA.....	95
Figura 32. Análisis gráfico de normalidad residual del modelo MLR .....	97
Figura 33. Correlaciones entre los descriptores del modelo .....	98
Figura 34. Diagramas de dispersión entre predictores y residuos del MLR .....	99
Figura 35. Influencia relativa de factores aportantes a LST .....	100
Figura 36. Perfiles LST y NDBI en un transecto urbano .....	102
Figura 37. Mapa térmico urbano - segmentación SVM.....	104
Figura 38. Mapa térmico urbano - segmentación WNB.....	106
Figura 39. Amplitudes de rango LST en áreas de entrenamiento .....	107
Figura 40. Funciones de densidad de probabilidad NDWI-SHT .....	108
Figura 41. Mapa de recomendaciones de planificación térmica urbana. ....	110
Figura 42. Recomendaciones de adaptación para la regulación térmica urbana.....	113

# Listado de figuras en apéndices

## Apéndice B

Figura B1. Certificado de calibración termómetro patrón .....	160
Figura B2. Modelo de ajuste termómetro patrón .....	161
Figura B3. Contraste lecturas T.prototipo contra T.patrón.....	162
Figura B4. Comportamiento general de los factores estudiados .....	164
Figura B5. Comportamiento de los datos remuestreados .....	164
Figura B6. Comportamiento de datos con eliminación de atípicos.....	165
Figura B7. Correlación entre variables seleccionadas por el modelo MLR.....	168
Figura B8. Distribución de frecuencias de residuales del modelo.....	170
Figura B9. Gráfica cuantil-cuantil de residuales del modelo .....	170
Figura B10. Dispersión de residuos NDBI .....	171
Figura B11. Dispersión de residuos NDVI.....	171
Figura B12. Dispersión de residuos NDWI.....	172
Figura B13. Dispersión de residuos PUC .....	172
Figura B14. Dispersión de valores ajustados del modelo contra sus residuos .....	173

# Listado de tablas

Tabla 1. Zonas de planificación climática .....	24
Tabla 2. Sensores térmicos usados en estudios de LST.....	26
Tabla 3. Resolución espectral de sensores térmicos.....	27
Tabla 4. Emisividades de referencia para recuperar LST desde L8/TIRS B10 .....	66
Tabla 5. Factores candidatos examinados como posibles descriptores de LST .....	74
Tabla 6. Coeficientes de las funciones Tasseled Cap para Landsat 5 TM.....	74
Tabla 7. Coeficientes de las funciones Tasseled Cap para Landsat 7 ETM+ .....	75
Tabla 8. Coeficientes de las funciones Tasseled Cap para Landsat 8 OLI.....	75
Tabla 9. Clasificación de LST en rangos térmicos .....	79
Tabla 10. Métricas de evaluación en la precisión de los clasificadores empleados .....	81
Tabla 11. Resultados ajustados del modelo MLR .....	96
Tabla 12. Contraste de supuestos del modelo MLR .....	96
Tabla 13. Coeficientes MLR estandarizados e influencia relativa de cada factor.....	99
Tabla 14. Parámetros de funciones de densidad de probabilidad.....	105
Tabla 15. Matriz de confusión segmentación SVM.....	108
Tabla 16. Matriz de confusión segmentación WNB.....	109
Tabla 17. Resultados de las métricas de precisión de clasificadores.....	109

## Listado de tablas en apéndices

### Apéndice A

Tabla A1. Identificación de las escenas L5, L7, L8, S2 empleadas en este estudio.....	157
---	-----

### Apéndice B

Tabla B1. Contraste mediciones T. patrón contra T. prueba .....	161
Tabla B2. Lecturas corregidas del termómetro en prueba .....	161
Tabla B3. Modelo de ajuste para T=20 °C empleando 5 observaciones .....	162

# Listado de abreviaturas

**AATSR** *Advanced Along-Track Scanning Radiometer*

**ABL** *Atmospheric Boundary Layer*

**AIC** *Akaike's Information Criterion*

**ANN** *Artificial Neural Network*

**ASTER** *Advanced Spaceborne Thermal Emission and Reflection Radiometer*

**ASTER-GED** *ASTER Global Emissivity Dataset*

**ASTER-GEDv3** *ASTER Global Emissivity Dataset Version 3*

**AVHRR** *Advanced Very-High-Resolution Radiometer*

**CBEM** *Classification-Based Emissivity Method*

**DANE** *Departamento Administrativo Nacional de Estadística*

**DEM** *Digital Elevation Model*

**D-W** *Durbin-Watson*

**EHT** *Extreme High Temperature*

**ENVISAT** *Environmental Satellite*

**ESA** *European Space Agency*

**EOS** *Earth Observing System*

**ETM+** *Enhanced Thematic Mapper Plus*

**F<sub>COVER</sub>** *Fraction of Vegetation Cover*

**FLAASH** *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*

**FROM-GLC** *Finer-Resolution Observation and Monitoring Global Land Cover*

**GCOS** *Global Climate Observing System*

**GHG** *Greenhouse Gas Protocol*

**GIS** *Geographical Information System*

**GWR** *Geographically Weighted Regression*

**HT** *High Temperature*

**IGAC** *Instituto Geográfico Agustín Codazzi*

**ISL** *Inertial Sub-layer*

**IQR** *Interquartile Range*

**JCR** *Journal Citation Reports*

**K-S** *Kolmogórov-Smirnov*

**LCZ** *Local Climate Zone*

**LSE** *Land Surface Emissivity*

**LST** *Land Surface Temperature*

**LT** *Low Temperature*

**LULC** *Land Use Land Cover*

**L5** *Landsat 5*

**L7** *Landsat 7*

**L8** *Landsat 8*

**ML** *Machine Learning*

**MLR** *Multiple Linear Regression*

**MODIS** *Moderate-Resolution  
Imaging Spectroradiometer*

**MODTRAN** *Moderate resolution  
atmospheric Transmission*

**MOD21** *MODIS LST Emissivity  
product*

**MSI** *Multispectral Instrument*

**MT** *Medium Temperature*

**NASA** *National Aeronautics and  
Space Administration*

**NCEP** *National Centers for  
Environmental Prediction*

**NDBI** *Normalized Difference Built-up  
Index*

**NDVI** *Normalized Difference  
Vegetation Index*

**NDWI** *Normalized Difference Water  
Index*

**NIR** *Near Infrared*

**NOAA** *National Oceanic and  
Atmospheric Administration*

**OA** *Overall Accuracy*

**OBIA** *Object-Based Image Analysis*

**OLI** *Operational Land Imager*

**OLI-2** *Operational Land Imager 2*

**OLS** *Ordinary Least Squares*

**PA** *Producer's accuracy*

**PC** *Principal Component*

**PCA** *Principal Component Analysis*

**PC1** *Principal Component 1*

**PDF** *Probability Density Function*

**PUC** *Proximity Urban Center*

**PW** *Proximity Water*

**RBL** *Rural Boundary Layer*

**RF** *Random Forest*

**RSL** *Roughness Sub-layer*

**RTE** *Radiative Transfer Equation*

**SD** *Standard Deviation*

**SLSTR** *Sea and Land Surface  
Temperature Radiometer*

**SUHI** *Surface Urban Heat Island*

**SUHII** *Surface Urban Heat Island Intensity*

**SHT** *Sub-High Temperature*

**SLT** *Sub-Low Temperature*

**SMT** *Sub-Medium Temperature*

**SNAP** *Sentinel Application Platform*

**SVM** *Support Vector Machine*

**SWIR** *Short-Wave Infrared*

**S2A** *Sentinel 2A*

**TC** *Tasseled Cap*

**TCB** *Tasseled Cap Brightness*

**TCG** *Tasseled Cap Greenness*

**TCW** *Tasseled Cap Wetness*

**TES** *Temperature Emissivity Separation*

**TIR** *Thermal Infrared*

**TIRS** *Thermal Infrared Sensor*

**TIRS-2** *Thermal Infrared Sensor 2*

**TM** *Thematic Mapper*

**TOA** *Top of Atmosphere*

**UA** *User's accuracy*

**UBL** *Urban Boundary Layer*

**UCAnMap** *Urban Climatic Analysis Map*

**UCL** *Urban Canopy Layer*

**UCMap** *Urban Climatic Map*

**UCPZ** *Urban Climatic Planning Zone*

**UC-ReMap** *Urban Climatic Recommendation Map*

**UHI** *Urban Heat Island*

**USGS** *United States Geological Survey*

**UTM** *Universal Transverse Mercator*

**VIS** *Visible bands*

**WGS84** *World Geodetic System 1984*

**WNB** *Weighted Naïve Bayes*

**WoS** *Web of Science*

“Cualquiera que haya estado dedicado seriamente a tareas científicas de cualquier clase se da cuenta de que en la puerta del templo de la ciencia están escritas las palabras: ‘*Debéis tener fe*’. Esta es una cualidad de la que los científicos no pueden prescindir”

Max Planck (1858 – 1947)

# CAPÍTULO 1

## INTRODUCCIÓN Y PLANTEAMIENTO GENERAL DEL PROBLEMA

**RESUMEN:** *Este capítulo proporciona el contexto general sobre el cual se desarrolló la investigación contenida en esta tesis. La primera sección 1.1, hace referencia de los problemas y desafíos de las ciudades para hacer frente al crecimiento demográfico y su concentración de actividades, que conducen al aumento de temperaturas del clima urbano. También, se describen de manera generalizada algunas de las variables asociadas al fenómeno y las técnicas empleadas para su medición. La sección 1.2 describe el problema de investigación de una temática que hasta ahora ha recibido poca o ninguna atención y que requiere mayor profundidad como la influencia relativa de las variables que explican la LST, y su integración bajo algoritmos de clasificación de aprendizaje automático. La sección 1.3 pone de manifiesto que la intervención de las actividades antropogénicas sobre el medio se encuentra altamente correlacionada con las alteraciones climáticas locales, y que las propiedades físicas de los elementos presentes en las cubiertas condicionan la*

*respuesta térmica superficial y en consecuencia la formación del fenómeno SUHI. Esto define el contexto que motiva las preguntas de investigación. La sección 1.4 sintetiza estas preguntas a través de los objetivos principal y específicos. Finalmente, la sección 1.5 describe los contenidos y la estructura de esta tesis.*

## **1.1 Contexto generalizado**

Los efectos combinados del calentamiento global, el crecimiento demográfico, y la expansión urbana causan un impacto determinante sobre el medio ambiente. La aparición de superficies impermeables como producto de las transformaciones humanas sobre su entorno ecológico, disminuyen la evapotranspiración y acrecientan la huella de carbono global sometiendo a la población a un diferencial de temperatura ampliamente registrado, entre el centro urbano y su periferia rural. Esta interacción que se reajusta continuamente sin control centralizado hace que la relación entre objetos y fenómenos se deba estudiar de manera sistémica para comprender sus relaciones. Los cambios en la cubierta del suelo ocasionados por la expansión urbana hacen que la interacción de las propiedades termodinámicas de estos nuevos entornos aumente la temperatura superficial terrestre (LST), ocasionando la distribución espacial del fenómeno de isla de calor urbano superficial (SUHI). Las SUHI se caracterizan por una diferencia de temperatura del suelo urbano y sus entornos rurales circundantes. Estas son el mejor ejemplo documentado de la alteración climática debido a orígenes antrópicos y su determinación evalúa el riesgo potencial de calor, por lo que es importante monitorearlas para una mejor orientación de la planificación urbana.

Aunque solo el 1% de la superficie terrestre es urbanizada contiene más de la mitad de la población del planeta con tendencia al alza, este aumento y el crecimiento de las ciudades son un problema global con propiedades emergentes por su impacto en la temperatura superficial terrestre ([United Nations, 2018](#)). Las últimas proyecciones de la ONU indican que la población urbana mundial seguirá creciendo en las próximas décadas. Según sus estimaciones más recientes, se espera que alcance los 5,6 mil millones de personas en 2035 y 6,7 mil

millones en 2050 (UN-Habitat, 2022). El cambio climático, el crecimiento poblacional y el ritmo de aumento urbanístico han sido algunos motivos para que la Asamblea General de las Naciones Unidas presentase en 2015 los *Objetivos de Desarrollo Sostenible* (ODS), compuesta por 17 metas que permitan acabar con la pobreza, proteger el planeta y lograr un futuro sostenible con cumplimiento de la agenda 2030 (United Nations, 2015). El seguimiento de estas metas se lleva a través de un marco global de indicadores que da soporte en 3 fases de desarrollo de los ODS: planificación, implementación y monitoreo del progreso (Liu et al., 2022). El ODS-11 hace referencia a la resiliencia urbana y la sostenibilidad de las ciudades. Este objetivo busca rediseñar los asentamientos urbanos poniendo de manifiesto la importancia de la cubierta vegetal y espacios abiertos para generar viabilidad ambiental y prosperidad al hacer frente al cambio climático local y las transformaciones del paisaje. La caracterización de las SUHI como un indicador climático señalan un aporte considerable al ODS-11 frente al rediseño urbano, dado que se podrían desarrollar políticas que apunten a mitigar áreas identificadas con exceso térmico (Wasif Ali et al., 2022).

La LST ha sido identificada como una variable climática esencial por el Sistema de Observación Climático Global (GCOS) de la Agencia Espacial Europea (ESA) (Guillevic et al., 2018) y otras organizaciones internacionales dedicadas a analizar los efectos del cambio climático (NASA, 2008), (IPCC, 2018). La LST es definida como la temperatura radiativa media de la piel de la Tierra, se deriva de la radiación térmica de los objetos que componen la superficie y es producida por la interacción entre la radiación solar entrante, los flujos de calor sensible/latente, y la radiación infrarroja terrestre saliente (International LST and Emissivity Working Group, 2018). La LST es un parámetro fundamental en la explicación de los procesos biofísicos que rigen la energía superficial y el balance hídrico. Sus variaciones medidas a partir de sensores térmicos son útiles para estudiar el clima urbano, evapotranspiración, y monitoreo de cambios biofísicos en cubiertas terrestres (Fonseka et al., 2019).

Los Sistemas de Observación de la Tierra (EOS) comenzaron a detectar la superficie terrestre a principios de la década de 1970. Varias misiones EOS, con una amplia gama de instrumentos a bordo se encuentran orbitando la Tierra, facilitando información relevante sobre el uso y la cobertura del suelo urbano, la

temperatura superficial y otras variables ambientales asociadas. SUHI es un fenómeno de alta variabilidad espaciotemporal que se puede describir cuantitativamente en función de la LST. En este contexto, el seguimiento de los procesos de la superficie terrestre a través de la teledetección se ha convertido en la forma más eficaz de obtener mediciones de LST y otra información relacionada con la cobertura terrestre. Los valores LST recuperados de los datos satelitales proporcionan un medio para comprender de manera eficiente los procesos de la superficie de la Tierra a través de una periodicidad constante, resolución espacial alta y cobertura global (Hu et al., 2016). Los sensores de infrarrojo térmico de las plataformas satelitales registran la temperatura como resultado del intercambio energético entre superficie y atmósfera asociado a la emisividad superficial terrestre (LSE). Además, la propiedad anisotrópica de reflectancias y emisividades influye en la cantidad total de radiación superficial que se distorsiona a medida que se propagan a través de la atmósfera (Li et al., 2013a). Bajo este enfoque, recuperar la LST de forma precisa es complejo y depende fundamentalmente de la LSE. Diferentes estudios han demostrado que las incertidumbres de LSE entre 0,006 y 0,015 produjeron diferencias de 1,0 y 1,5 °C en la recuperación de LST (Li and Meng, 2018), (Li et al., 2019), (Saradjian and Jouybari-Moghaddam, 2019).

La LST se encuentra influenciada por una amplia variedad de factores, detectar su importancia relativa puede representar implicaciones significativas en la gestión de sistemas ecológicos, priorizando los factores más críticos (Q. Wang et al., 2022). La regresión lineal múltiple (MLR) ha sido empleada por distintos autores para definir la correlación y el aporte de los factores explicativos de LST (Huang and Wang, 2019), (Zeng et al., 2021). Los cambios en el uso y la cobertura del suelo (LULC) y diferentes índices espectrales de diferencia normalizada, como los de construcción (NDBI), vegetación (NDVI) y agua (NDWI), han sido ampliamente utilizados para investigar las relaciones entre los sistemas urbanos y biofísicos, así como su impacto en la temperatura superficial (Guha et al., 2022) (Aslan and Koc-San, 2021), (Marković et al., 2021). La compleja interacción entre LST y sus factores impulsores conducen a la heterogeneidad espacial del patrón SUHI. Estas interacciones pueden ser analizadas con una técnica de modelación que revele sus tendencias espaciotemporales. El análisis de componentes principales (PCA) reduce la dimensionalidad de datos, elimina

redundancias e identifica patrones a través de un procedimiento de transformación lineal (Azam et al., 2018). Varios investigadores han empleado la técnica PCA para detectar patrones de variación espaciotemporal de LST y otras variables ambientales asociadas (Lemus-Canovas et al., 2020), (Song et al., 2021), (John et al., 2021). Los cambios de LULC se deben a interacciones complejas entre el sistema urbano y el entorno biofísico que producen cambios significativos en la temperatura local. Dutta et al., (2022) emplearon PCA para demostrar que la transformación del paisaje y los cambios de LULC fueron los principales causantes del deterioro del ambiente térmico urbano.

*El aprendizaje automático* (ML) es una técnica de inteligencia artificial, que se presenta como una forma adecuada de tratar la complejidad del proceso de modelación climática, dado que tiene en cuenta las interacciones lineales y no lineales de las variables predictoras y las de respuesta (Pal and Sharma, 2021), (Lezama Valdes et al., 2021). Diversos autores han utilizado algoritmos ML como técnica de aprendizaje supervisado para analizar factores asociados a los cambios térmicos urbanos y detectar sus áreas de máxima intensidad (Seebacher et al., 2019), (McCarty et al., 2021), (Oliveira et al., 2022).

El principal objetivo de esta investigación es caracterizar el fenómeno SUHI en una ciudad tropical andina colombiana (Cartago) producido por las actividades antrópicas en el periodo 2001-2020, a través de la distribución multitemporal de temperaturas medidas con técnicas de teledetección, como medio para contribuir con las dinámicas socioambientales de planificación y gestión territorial urbana sostenible al gobierno local. Para lograrlo, se utilizó una combinación de técnicas de análisis de componentes principales (PCA) y regresión lineal múltiple (MLR) integradas con algoritmos de aprendizaje automático para detectar patrones de alta intensidad térmica. En este estudio se integra la influencia relativa de las variables que intervienen en el fenómeno empleando el algoritmo *Weighted Naïve Bayes* (WNB), como clasificador ponderado para segmentar el espacio geográfico en unidades de diferente intensidad térmica. A través de la segmentación derivada de estos algoritmos, se logró categorizar el entorno urbano de acuerdo con un mapa de recomendaciones térmicas urbanas que identifica las islas de calor y presenta diferentes estados de

advertencia, lo que permite a los planificadores del territorio, definir acciones de mitigación y adaptación de confort térmico.

## 1.2 El problema

El cambio climático inducido por el calentamiento global y provocado por el ser humano es claramente la amenaza planetaria a mediano plazo de mayor importancia para la vida en la Tierra. Sus causas y efectos están plenamente identificados. Ante este desafío, los gobiernos deberán aplicar políticas adecuadas para mitigar su efecto y adaptar a las poblaciones. Las ciudades son la expresión más visible de la influencia humana en el planeta. El movimiento migratorio hacia las capitales en busca de mejores condiciones implica procesos de transformación espacial, ambiental y social representados en la expansión urbana. Estos cambios en el medio conllevan a cambios en el uso del territorio adaptándolos a las necesidades de una creciente sociedad ávida de espacio y recursos.

El desarrollo económico y social de las áreas urbanas avanza en paralelo con el aumento de la población humana. Actualmente, el 55% de la población mundial habita en zonas urbanas, y se espera que aumente al 68% en 2050 ([United Nations, 2019](#)). El rápido aumento de la población y el crecimiento no planificado desbordan la capacidad de infraestructuras de servicios públicos con consecuencias económicas, sociales y ambientales negativas. Bajo este enfoque, las ciudades se constituyen en instrumentos de modificación antrópica del medio natural, afectando sus condiciones climáticas.

La estructura urbana incluye una combinación de fenómenos complejos, que interactúan a diferentes escalas. Los mecanismos de transferencia térmica y conservación de energía como la conducción, convección y radiación, juegan un papel importante en el intercambio de calor. La capacidad de absorción energética que poseen las superficies impermeables, los espacios verdes sin riego y los materiales de construcción, almacenan continuamente radiación en forma de energía térmica durante el día, y lo irradian lentamente en la noche. Esta interacción altera el balance radiativo entre suelo y aire, disminuyendo la evapotranspiración y creando anomalías que afectan el confort térmico, agravan

la contaminación del aire urbano y producen efectos adversos sobre la salud humana (Tran et al., 2017), (Yang et al., 2017). Adicionalmente, el consumo energético con fines de refrigeración tiende a duplicarse y por tanto, exceder la demanda máxima de electricidad representada en aumento del calor antropogénico (Yang et al., 2017), (Santamouris, 2014). SUHI es un fenómeno que señala mayores temperaturas superficiales terrestres en las áreas urbanas de alta densidad poblacional comparadas con las áreas circundantes. El fenómeno es causado por las propiedades térmicas y radiativas de superficies impermeables, la reducción de la cubierta vegetal y el exceso de consumo energético (Miles and Esau, 2017), (Li and Zha, 2019). En los países Latinoamericanos y del Caribe este tema cobra importancia ya que, las ciudades en el año 2009 albergaron cerca del 90% de la población (United Nations, 2010). Diversos estudios han documentado ampliamente la influencia de factores ambientales como NDBI, NDVI, y NDWI sobre el fenómeno SUHI (Kumar and Shekhar, 2015), (Alves et al., 2020), (Chakraborty et al., 2020). Conocer la influencia relativa de los factores que definen la temperatura, es sin duda un punto interesante, dado que, la identificación de aquellos factores que generan mayor dominio podría ser empleados para definir estrategias específicas de adaptación al cambio térmico que producen, reduciendo sus impactos negativos.

El proceso de urbanización ha modificado la cubierta del suelo y transformado la estructura de la superficie urbana, provocado su aumento térmico. Es interesante la relación que existe entre la actividad humana y la naturaleza, somos responsables por los efectos que producen nuestras actividades: el cambio en el uso del suelo y la explotación de recursos naturales limitados generan cierta tensión, que hace que estemos en necesidad de desarrollar modelos que nos permitan comprender la variabilidad térmica urbana, para definir los principios de prevención y mitigación de impactos. Hallazgos presentados por Huang et al., (2019) señalan que en promedio global, el calentamiento ocasionado por la isla de calor urbano será equivalente a la mitad del calentamiento causado por el cambio climático para el año 2050. Esto sugiere que las poblaciones urbanas que estén experimentado calentamiento a causa del cambio climático, y que vivan en condiciones de islas de calor, podrían incrementar sus índices de vulnerabilidad térmica.

Las ciudades sostenibles son una de las metas de los *Objetivos de Desarrollo Sostenible* (ODS) publicadas en el informe emitido por ONU-Hábitat ([United Nations, 2015](#)). El ODS-11 tiene como objetivo mejorar los estándares de vida y fortalecer la economía sin impactar negativamente el medio ambiente. Así mismo, brinda soporte a los gobiernos nacionales y locales en el avance del desarrollo urbano inclusivo integrando espacios públicos verdes para contribuir hacia el logro de ciudades sostenibles seguras y resilientes. Sin embargo, la sostenibilidad del territorio no es alcanzable si se desconocen las tendencias de la urbanización y sus impactos.

Nuestros problemas ambientales son visibles y técnicamente perceptibles, pero ¿qué aspectos tienen las soluciones? La necesidad de optimizar la planificación urbana para adaptarse al aumento térmico requiere un soporte que aún no se define completamente: caracterizar el patrón térmico de la ciudad en función de las tendencias multitemporales de los factores ambientales asociados al fenómeno. Esto pone de manifiesto el reto de mejorar las técnicas existentes, desarrollando una metodología, que integre procedimientos estadísticos, observaciones de campo, e imágenes satelitales, para modelar patrones y definir la contribución de cada factor ambiental en tiempo y espacio, e integrarlos a través de un algoritmo de aprendizaje automático que pondere dichos aportes para segmentar el área en unidades térmicas, y reproducir un mapa con propuestas de acción que permitan preservar aquellas zonas que se han mantenido frescas, e intervenir aquellas que presenten excesos térmicos. Nuestros sistemas urbanos se caracterizan por un bajo nivel de resiliencia climática, por tanto, es necesario un enfoque integral de competencias tecnocientíficas que permita una mejor capacidad de adaptación climática de las políticas globales en acciones locales. En la medida en que se comprenda el mecanismo térmico urbano en tiempo y espacio, se podrán involucrar políticas necesarias para la resiliencia climática del territorio, incrementando esquemas de rehabilitación para contrarrestar los efectos del fenómeno SUHI.

## 1.3 Motivación

La presentación del tema de *islas de calor urbano* por el Profesor Francisco Luis Hernández Torres, de la Universidad del Valle (Colombia), durante un evento internacional de Topografía y Geomática en el año 2009, me generó gran curiosidad acerca de la manera en que se mide aquello que no se puede ver, *la temperatura de la superficie terrestre*. Esto fue sin duda, el origen de mi interés sobre las aplicaciones de climatología urbana desde los sensores térmicos a bordo de las diferentes plataformas de los EOS.

Muchas áreas están cambiando rápidamente debido a los efectos de expansión del cambio climático y la actividad progresiva. El crecimiento de la urbanización y el impacto potencial del aumento térmico ocasionado por distintas descargas antropogénicas, plantean desafíos que los planificadores territoriales deben superar. La identificación de la variabilidad espaciotemporal del fenómeno SUHI a través de los EOS, conduce a mejorar la comprensión de las causas e implicaciones de estrés térmico. En este contexto, surge la motivación de la presente Tesis Doctoral, la cual se enfoca en diseñar una metodología que emplea técnicas de modelación estadística y aprendizaje automático, para caracterizar los efectos de distintas variables ambientales que contribuyen en la formación del fenómeno SUHI. Las preguntas de investigación subyacentes que proporcionan la motivación para esta tesis son:

- *¿Cuáles son los factores dominantes del exceso de temperatura urbana en el área de estudio?,*
- *¿Cuál es la tasa de contribución de cada factor? y,*
- *¿Es posible integrar la importancia relativa de cada factor, en un algoritmo de aprendizaje automático, para buscar un mejor resultado de segmentación térmica, que el obtenido con algoritmos que no ponderen dichos factores?*

En general, esta problemática se centra alrededor del cuestionamiento de si el clima urbano puede o no ser racionalmente planeado y controlado. Este estudio introduce un enfoque para segmentar áreas con diferentes niveles de exceso térmico, y contribuye a la planificación de medidas de adaptación y mitigación específicas, en busca de la sostenibilidad térmica del territorio y sus pobladores. Con la caracterización del fenómeno SUHI, la planificación urbana

se puede enfocar hacia un modelo resiliente, sostenible y seguro de nuestras ciudades como se describe en los *Objetivos de Desarrollo Sostenible de ONU-Hábitat*, promoviendo modelos que contribuyan al rediseño de las ciudades basados en consideraciones climáticas.

## 1.4 Objetivos de la investigación

### 1.4.1 Objetivo principal

Caracterizar el fenómeno SUHI en una ciudad tropical andina colombiana (Cartago), a través de la distribución multitemporal de temperaturas en el periodo 2001-2020 integrando técnicas de teledetección, observaciones de campo y algoritmos de aprendizaje automático, como medio para contribuir con las dinámicas socioambientales de planificación y gestión territorial urbana sostenible al gobierno local.

### 1.4.2 Objetivos específicos

- (1) Contrastar el comportamiento de LST a partir de distintos modelos de emisividad (valores de referencia de diferentes autores (CBEM), el ASTER GEDv3, y,  $F_{COVER}$  propuesto por [Valor and Caselles, \(1996\)](#)).
- (2) Calcular la LST usando imágenes multiespectrales de Landsat 5 TM, 7 ETM+, 8 OLI/TIRS y Sentinel 2-MSI a partir de la implementación de un algoritmo monocanal.
- (3) Estimar la tendencia temporal de factores ambientales como NDVI, NDBI, NDWI, y la transformación *Tasseled Cap*, para definir su relación e influencia relativa sobre la LST.
- (4) Proponer un modelo del fenómeno SUHI que integre técnicas estadísticas y algoritmos de aprendizaje automático, para segmentar el espacio en regiones de diferente intensidad térmica.
- (5) Proponer recomendaciones de mitigación sobre las áreas afectadas.

## 1.5 Descripción del contenido de la tesis

Esta tesis está estructurada en 7 capítulos así: *Capítulo 1: Introducción y planteamiento general del problema*, donde se presenta el proyecto de investigación a través de una visión integral del fenómeno SUHI, indicando el problema central, motivación, y objetivos. *Capítulo 2: Antecedentes teóricos*, que expone las consideraciones pragmáticas a través del estado del arte, los influyentes del fenómeno y la importancia de los sensores térmicos en la recuperación de LST. *Capítulo 3: Área de estudio y materiales*, presenta las generalidades de la ciudad sobre la que se analizó el fenómeno, el origen de los datos empleados en la investigación y las consideraciones técnicas de los termómetros portátiles para obtener mediciones directas de temperatura. *Capítulo 4: Diseño metodológico*, describe los factores que se han evaluado como más relevantes para la modelización del fenómeno, las técnicas estadísticas empleadas para la detección de sus tendencias espaciotemporales, y la modelación SUHI a través de algoritmos de aprendizaje automático. *Capítulo 5: Resultados y discusión*, que expone y describe los productos obtenidos y la contribución del autor, contrastando estudios previos de otros autores con los resultados más importantes de este proyecto, en términos del análisis de sensibilidad LST/LSE, los modelos estadísticos implementados y la propuesta de modelación del fenómeno SUHI para la producción del mapa de recomendaciones térmicas urbanas. *Capítulo 6: Conclusiones*, se condensan reflexiones en torno a la situación problemática definida anteriormente, destacando los aportes de la investigación de manera precisa, así como las limitaciones y futuras líneas de investigación. Por último, en el *Capítulo 7* se detalla la *Bibliografía* utilizada, haciendo referencia expresa de las citas que contiene el texto. Con esta distribución se ha pretendido conseguir una lectura del trabajo de manera fluida y coherente. Adicionalmente, se presentan distintos apéndices que incluyen, el listado de imágenes satelitales procesadas, modelo de verificación y ajuste de termómetros, códigos fuente del modelo de regresión e implementación del algoritmo WNB.

“Nada en la vida es para ser temido, es sólo para ser comprendido. Ahora es el momento de entender más, de modo que podamos temer menos”

Marie Curie (1867 – 1934)

## CAPÍTULO 2

# ANTECEDENTES TEÓRICOS

**RESUMEN:** *La exposición del estado del conocimiento referido a un tema tan extenso y variado como el de SUHI, que por su interés ambiental y desarrollo son acelerados, obliga a que en estas páginas se sintetice lo que a mi parecer posee una mayor relación con el contenido de la investigación, obviando asuntos que desde otras ópticas pudieran parecer de mayor relevancia. A ello, se suma el hecho de que se realiza en un espacio temporal limitado, durante el cual surgen numerosas aportaciones procedentes de investigadores que, a escala global dirigen sus esfuerzos hacia temáticas similares a las aquí tratadas. Las diversas aplicaciones de la temperatura en actividades de gestión de los recursos naturales han puesto de manifiesto la importancia de los sistemas de observación de la Tierra (EOS). Las imágenes térmicas recuperadas de los sensores satelitales proporcionan un respaldo científico que integradas con los sistemas de información geográfica (GIS) y modelación estadística, permiten valorar la sostenibilidad ambiental. La LST es el parámetro más importante para estudiar la climatología urbana y la variable fundamental para detectar los fenómenos asociados a los cambios térmicos. En la sección 2.1 se llevó a cabo una revisión literaria amplia y actual, para definir los conceptos asociados al aumento calórico de las ciudades como UHI, SUHI, SUHII, y hacer un balance sobre las tendencias de investigación, las técnicas que se emplean para la medición del fenómeno, y sus factores influyentes. La sección 2.2 trata los conceptos teóricos subyacentes a la interacción radiación–atmósfera–superficie. Las partículas, aerosoles y gases presentes en la atmósfera afectan la cantidad de luz y la radiación entrantes. Estos efectos causados por*

*los mecanismos de dispersión y absorción se ven reflejados en la imagen satelital, poniendo de manifiesto la importancia realizar la corrección de efectos atmosféricos como parte fundamental del preprocesamiento de imágenes. La sección 2.3 trata de manera profunda los modelos físicos de los datos registrados por plataformas satelitales en el dominio espectral del infrarrojo térmico, para la recuperación de LST a partir de técnicas de teledetección, evidenciando su dependencia de los valores de emisividad superficial e identificando diversas fuentes para obtenerla. La sección 2.4 refiere la técnica de análisis de componentes principales (PCA), como modelador de tendencias de datos de series temporales de sistemas dinámicos como LST y sus factores ambientales asociados. También, se expone la regresión lineal múltiple (MLR) como técnica de modelación estadística para la definición de variables contributivas a LST. Finalmente, la sección 2.5 señala los fundamentos de 2 modelos de aprendizaje automático (SVM y WNB) que serán empleados para la segmentación de mapas LST en unidades de diferente intensidad térmica; todo esto para marcar un punto de partida en el desarrollo de este proyecto que identifica el fenómeno SUHI como un contribuyente importante a la agenda de sostenibilidad a escala urbana.*

## **2.1 Estado del arte**

La tasa actual de calentamiento global no tiene precedentes en al menos los últimos 11.700 años. La investigación científica ha demostrado que el clima de la Tierra ha experimentado de forma natural ciclos de calentamiento y enfriamiento durante largos períodos de tiempo. Los cambios están relacionados con las variaciones en la órbita terrestre y la cantidad de energía solar que recibe el planeta. Esto se presenta en escalas de tiempo de decenas de miles a cientos de miles de años y son impulsados por interacciones complejas entre la atmósfera de la Tierra, los océanos y el sistema climático. Sin embargo, la tendencia actual del calentamiento está ocurriendo a un ritmo mucho más rápido de lo que puede explicarse únicamente por factores naturales (NASA, 2023).

El consenso científico ha documentado ampliamente que las actividades humanas, en particular la quema de combustibles fósiles, son la causa principal de la actual tendencia al calentamiento. Si bien los factores naturales desempeñan un papel en la configuración del clima de la Tierra, sus efectos son mucho más lentos y menos pronunciados que los de las actividades humanas. Este cambio se da particularmente en las ciudades, pues la cubierta natural está siendo

modificada de manera drástica creando nuevos usos del suelo para adaptarlos a las condiciones de una creciente sociedad necesitada de espacio y recursos que amenaza los mecanismos vitales de nuestro sistema terrestre. Desde esta óptica medioambiental las ciudades se constituyen en instrumentos de modificación antrópica del medio natural, afectando especialmente las condiciones climáticas. El *Acuerdo de París* adoptado en 2015 busca limitar el aumento de la temperatura media mundial a 1,5 °C por debajo de los niveles preindustriales. El reporte de [IPCC, \(2022\)](#) señala que las emisiones de gases de efecto invernadero (GHG) durante la última década están en los niveles más altos en la historia humana. Para reducir las emisiones de GHG y contribuir a la mitigación del cambio climático, se requieren regulaciones de gestión ambiental estrictas en diferentes sectores. Estas regulaciones pueden incluir políticas de incentivos y sanciones que fomenten la adopción de tecnologías más limpias y eficientes, así como medidas para promover la conservación y restauración de ecosistemas.

NASA y otras organizaciones científicas utilizan los sistemas de observación de la Tierra (EOS) para estudiar el clima y comprender los efectos de los GHG. Sus sensores a bordo miden la cantidad de radiación infrarroja que es absorbida y reemitida por la atmósfera. Esta radiación se ve directamente afectada por la concentración de gases de efecto invernadero. Analizando estas mediciones se pueden comprender mejor la relación entre los gases atmosféricos y la temperatura de la Tierra.

En la última década la trascendencia política, social, y económica del fenómeno de la expansión urbana ha llamado fuertemente la atención de las ciencias geográficas otorgándole un lugar protagónico en los paradigmas de desarrollo regional ([Gaur and Singh, 2023](#)). Los procesos migratorios hacia las capitales, la concentración de la población y su ocupación espacial sobre el territorio hacen que la naturaleza se vea modificada drásticamente. Esta acción de fragmentación del hábitat obliga a que las ciudades generen sus propias condiciones medioambientales. Con la urbanización y el cambio del paisaje, el clima local se modifica dando lugar al fenómeno de isla de calor urbano superficial, caracterizado por el incremento térmico en la ciudad frente al medio rural debido a actividades antrópicas, y la sustitución de superficies naturales por artificiales con diferentes propiedades térmicas que impactan permanentemente el intercambio de flujos de energía y agua entre la superficie terrestre y la atmósfera; ocasionando desbalances radiativos locales. Esto da

lugar a gradientes térmicos alterados que son controlados por la estructura urbana y las propiedades físicas de sus constituyentes. Esta sobrecarga térmica amenaza gravemente el desarrollo urbano sostenible en el contexto del aumento global de las temperaturas asociado al cambio climático.

El fenómeno SUHI ha sido ampliamente documentado, pero sus características precisas resultan particulares de cada ciudad. Los EOS han permitido a la comunidad científica monitorear y modelar este fenómeno para tener una visión global y comprender su mecanismo desde las interacciones tierra/clima. Las ciudades y sus pobladores enfrentan distintos niveles de riesgo y vulnerabilidad, por tanto, disminuir los impactos térmicos y mantener un desarrollo urbano sostenible requiere implementar métodos analíticos confiables locales de manera sistémica e integrada para comprender la dinámica del aumento de LST, incluidos sus factores impulsores, patrones espaciales, tendencias e intensidad, especialmente en los países en vía de desarrollo por su particular grado de vulnerabilidad asociada a su falta de recursos y capacidad de adaptación.

En la literatura científica se hace la distinción entre la isla de calor urbano (UHI), y la isla de calor urbano superficial (SUHI). La UHI representa la diferencia de temperatura del aire entre las zonas urbana y rural (Voogt and Oke, 2003), los datos primarios para su modelación se obtienen de estaciones meteorológicas terrestres que registran valores específicos de la temperatura del aire, no obstante, estas estaciones solo representan el microclima local a su alrededor (Oke, 2006). La alta heterogeneidad en las áreas urbanas hace que la temperatura sea espacialmente diversa, lo que dificulta que un número limitado de estaciones represente de manera precisa la variabilidad térmica, además de los altos costes de su instalación (Chakraborty et al., 2021). Un enfoque directo se puede dar a través de un conjunto observaciones de la Tierra, como las obtenidas desde sensores remotos (Hu and Brunsell, 2015). Cuando el fenómeno es monitoreado con técnicas de teledetección se conoce como SUHI dado que la variable biofísica considerada es la temperatura superficial terrestre (LST) (Sobrino et al., 2013). Los satélites proporcionan una fuente de datos superior en la estimación de LST debido a sus observaciones repetibles a gran escala de la superficie terrestre (Weng, 2009), (Lu et al., 2020). Las SUHI llegan a su máxima intensidad durante el día cuando el sol calienta las distintas cubiertas de la

superficie, y decrece en la noche. Por su parte, las UHI, alcanzan su máximo en la noche cuando el aire sobre la ciudad se calienta debido a la disipación de calor de las superficies urbanas (Yang et al., 2020), (Arellano and Roca, 2021). Por lo tanto, el sobrecalentamiento de la superficie (SUHI) conduce a un aumento del fenómeno UHI causado por la transferencia de calor entre la superficie y la atmósfera. Los efectos por aumento térmico en las ciudades presentan implicaciones directas sobre los servicios ecosistémicos, reducción de la biodiversidad (Čeplová et al., 2017), disminuciones en los niveles de calidad de vida (Filho et al., 2021), calidad del aire y disponibilidad de agua (Wang et al., 2015). El SUHI combinado con fenómenos naturales como las olas de calor, puede aumentar la frecuencia y duración de eventos de calor extremo potenciando sus impactos en la salud humana y aumentando los índices de mortalidad de adultos mayores vulnerables (Kong et al., 2021).

El intercambio de energía entre la Tierra y la atmósfera define el balance de la energía superficial para evaporar el agua y modificar la LST. Los cambios en las cubiertas del suelo generan alteraciones en este intercambio, provocando un forzamiento radiativo que resultan en el desbalance en la ecuación de energía superficial representado en la [Figura 1](#). Analizar LULC a través de la ecuación de balance de energía superficial es importante para comprender los efectos de las modificaciones antrópicas sobre el clima local. En el fenómeno SUHI, la diferencia en las propiedades superficiales de las áreas urbanas frente a las rurales conduce a la diferencia en los flujos térmicos de la [Ecuación 1](#).

$$Q^* + Q_E + Q_H + Q_A + Q_G = 0 \quad (1)$$

La LST es una expresión de las diversas densidades de flujos de calor. Muy poca de la energía producida por la radiación neta ( $Q^*$ )<sup>1</sup> se almacena en el suelo de forma directa ( $Q_G$ ). La mayor parte se emite como flujos de calor latente ( $Q_E$ ) y sensible ( $Q_H$ ). Luego, la energía latente se libera a la atmósfera como producto de la evaporación del agua superficial por el calor latente de vaporización. SUHI

---

<sup>1</sup>  $Q^*$  está compuesta por  $Q_S$  y  $Q_L$  que son la radiación solar incidente y la radiación infraroja de onda larga emitida por la superficie terrestre, respectivamente.

ocurre como resultado del incremento del flujo de calor sensible ( $Q_H$ ) compuesto por radiación solar y el calor emitido debido a la descarga antropogénica ( $Q_A$ ) (Qu et al., 2020).

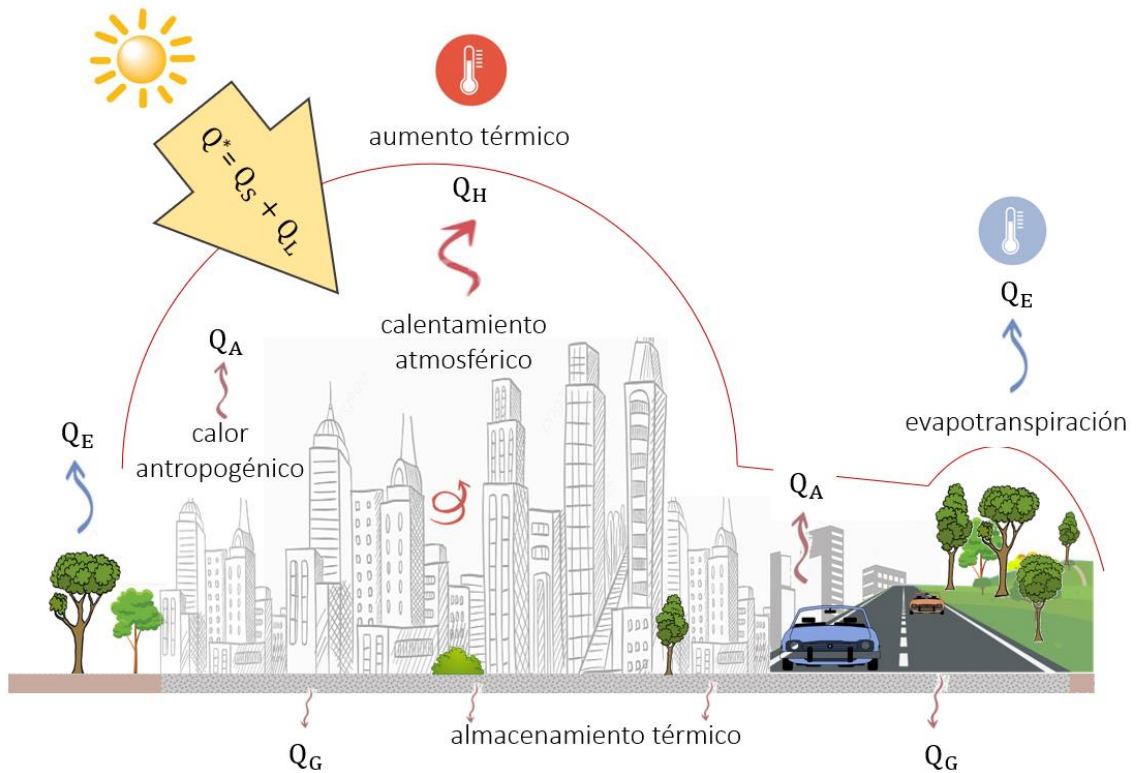


Figura 1. Componentes de la ecuación de balance de energía superficial

Para medir la magnitud de las UHI Stewart and Oke, (2012) propusieron el concepto de “zonas climáticas locales” (LCZ). Su objetivo es interpretar los patrones de temperatura en el contexto urbano caracterizando la forma de la superficie y la cobertura del área circundante para asociarlo a una clasificación estandarizada. Las LCZ son un sistema de clasificación universal que agrupa los contextos urbanos y naturales en 17 unidades, basadas en las propiedades físicas y geométricas de la superficie (10 en construcciones y 7 en tipos de cubierta terrestre), cada una de las cuales representa características térmicas locales únicas (Núñez-Peiró et al., 2021). Las LCZ de construcción (LCZ-1–10) se clasifican según la compacidad, altura de las edificaciones, materiales de construcción y

actividades humanas. Las LCZ de cubierta terrestre (LCZ-A–G) se clasifican por densidad y altura de la vegetación (Stewart and Oke, 2012), (Chen et al., 2020).

De acuerdo con Gao et al., (2020) este enfoque ha sido ampliamente aceptado por la literatura científica para clasificar el área urbana y sus alrededores con fines de investigación del clima urbano, y resulta útil para proponer estrategias de planificación que permitan mitigar el aumento térmico local. No obstante, Bechtel et al., (2015) señalaron que el mapeo de las LCZ es delicado porque unidades similares en diferentes regiones tienen propiedades espectrales distintas debido a las diferencias en la vegetación y los materiales de construcción. Bechtel et al., (2019) realizaron una comparación de SUHI en 50 ciudades usando el modelo LCZ. Hallaron variaciones importantes en los patrones térmicos que podrían estar asociados a parámetros fenológicos, topográficos y clases mixtas en unidades adyacentes, sin embargo, afirman que la implementación de amplias series temporales de LST y LCZ pueden aplicarse para analizar SUHI entre ciudades de diferentes tamaños y macroclimas circundantes.

El término *intensidad de isla de calor urbana superficial* (SUHII), es un indicador de la intensidad de SUHI comúnmente usado para hacer análisis comparativos, por ejemplo, la variación espaciotemporal de SUHI diurna y nocturna, entre ciudades, o distintas temporadas climáticas (Li et al., 2021). En los últimos años, se han publicado una serie de revisiones bibliográficas sobre las UHI/SUHI/SUHII que se han centrado en las líneas investigación, metodologías, variables asociadas y perspectivas de desarrollo científico. Por ejemplo, Mirzaei, (2015) identificó que las principales líneas de interés para la modelación de UHI incluyen, circulación del aire urbano, mejoramiento de modelos de evaluación, simulación térmica y ahorro energético en procesos constructivos. Ward et al., (2016) propusieron un indicador para determinar la carga de calor adicional durante una ola de calor y su relación con SUHI en 70 ciudades europeas. Sus hallazgos señalaron que las ciudades con climas más fríos y mayor proporción de espacios verdes urbanos —*las del norte de Europa*— fueron más afectadas durante las olas de calor, mientras que las del sur parecieron adaptarse mejor.

Chapman et al., (2017) hicieron una revisión sistemática de la literatura en el periodo 2000-2016, y resaltaron la importancia de integrar diversos factores a los

estudios SUHI como cambio climático, estrés por calor, variación en la densidad urbana, y el impacto del calor antropogénico. [Deilami et al., \(2018\)](#) analizaron 75 estudios sobre SUHI y evidenciaron la necesidad de integrar diversas fuentes de datos satelitales para mejorar los patrones de LST y técnicas avanzadas de aprendizaje automático (ML) para representar la complejidad del fenómeno. [Wu and Ren, \(2019\)](#) usaron un enfoque cuantitativo para estudiar más de 2800 publicaciones de la colección principal de *Web of Science* (WoS), que les permitió identificar dos principales líneas tendencias en investigación SUHI: impactos negativos en la salud pública y estrategias de mitigación y adaptación al fenómeno.

El ritmo creciente de la urbanización y el aumento de la frecuencia y duración de los eventos de calor extremo, sugieren los estudios de olas de calor como una dirección para la investigación de UHI. [Zhou et al., \(2019\)](#) aplicaron una revisión sistémica para el periodo 1972-2019 de estudios SUHI y sugirieron la integración de una amplia cantidad de datos satelitales, observaciones de campo y modelos numéricos para dar solidez a las tendencias térmicas. Así mismo, señalaron la relevancia de generar mayor investigación en Suramérica por su potencial de urbanización y vulnerabilidad al cambio climático, asociado a su alto nivel de pobreza. [Kim and Brown, \(2021\)](#) realizaron una revisión en profundidad de 51 estudios SUHI destacando la necesidad de desarrollar un modelo de estimación del fenómeno asociado a la forma tridimensional de la ciudad. [Rodrigues de Almeida et al., \(2021\)](#) aplicaron un análisis bibliométrico con más de 500 publicaciones en *Scopus* y *WoS* señalando que la investigación en el campo SUHI ha aumentado en 68% desde 2017 y que China, India, y Estados Unidos son los países con mayor número de publicaciones en revistas de alto impacto. También señalaron que los productos Landsat fueron los más empleados para estimar LST.

Según reportes oficiales de Colombia emitidos por [IDEAM, \(2017\)](#) la temperatura entre 1980 y 2011 ha tenido un incremento de 0,20 °C por década. Los datos de la temperatura del aire revelan tendencias crecientes de 0,8 °C cada 25 años en la temperatura media y 1,0 °C cada 25 años en temperatura mínima. Estas tendencias son consideradas mayores que las globales e incluyen los efectos locales de procesos de urbanización, deforestación y crecimiento poblacional. En algunas ciudades colombianas como Bogotá, Cali, Bucaramanga y Manizales se

han analizado las UHI y SUHI con resultados interesantes. Por ejemplo, [Ramírez-Aguilar and Lucas Souza, \(2019\)](#) presentaron un estudio UHI para la ciudad de Bogotá destacando que densidades poblacionales superiores a 14.500 hab/km<sup>2</sup> producen aumentos de 1 °C. Así mismo, señalan que el fenómeno presentó formas concéntricas y que no disminuyó en la medida que se alejó del centro de la ciudad. Esta distribución heterogénea relaciona de manera directa las condiciones morfológicas de la ciudad con el aumento térmico. La Corporación Autónoma Regional del Valle del Cauca realizó un estudio sobre la presencia de las SUHI en la ciudad de Cali empleando imágenes satelitales y estaciones meteorológicas. Se encontró que las causas del fenómeno se asocian a la falta de vegetación, uso intensivo del suelo y la obstrucción de edificaciones que impiden la circulación del aire. El estudio propone estrategias de mitigación como la inclusión de parques, implementación de techos verdes, y el mejoramiento de ventilación natural en edificios ([CVC et al., 2015](#)). En la ciudad de Bucaramanga [Villamil-Almeida et al., \(2020\)](#) diseñaron una red de monitoreo térmico en tiempo real para analizar tendencias de la intensidad UHI diurna y nocturna. Detectaron que la intensidad nocturna fue uniforme con intensidad media de 1 °C, mientras que el análisis diurno señaló alta variabilidad asociada a las propiedades locales de la superficie. Los resultados de la tesis de [Roncancio, \(2015\)](#) indicaron que la ciudad de Manizales presenta islas de calor tanto en la temperatura del aire como la superficial. El gradiente térmico de la ciudad indicó que las mayores temperaturas se encontraron en el centro de la ciudad y disminuyó hacia las áreas periféricas. Se presentaron diferencias de hasta 4 °C entre áreas urbanas y las rurales circundantes.

En los estudios revisados para Colombia se evidencia que la intensidad del fenómeno térmico se encuentra altamente influenciado por características urbanas como densidad poblacional, altura de las edificaciones y distribución de áreas verdes. Sin embargo, es notable la necesidad de profundizar en el uso de técnicas de aprendizaje automático (ML) para procesar grandes volúmenes de datos y detectar patrones difíciles de identificar mediante métodos convencionales. En este sentido, el uso de técnicas ML integradas con sistemas de monitoreo en tiempo real pueden proporcionar una forma más amplia de analizar las SUHI y su relación con distintos factores urbanos.

La teledetección ha contribuido a avances significativos en métodos aplicados para comprender la dinámica socioeconómica, ambiental y de los ecosistemas. La creciente integración de los modelos de aprendizaje automático y los avances en la tecnología de sensores remotos permiten mejorar la toma de decisiones aprovechando el gran volumen de datos disponible. En este sentido, la investigación en este campo apunta hacia la modelación de distribución espacial de intensidades térmicas, empleando técnicas de aprendizaje automático como, Random Forest (RF), Support Vector Machine (SVM), Redes Neuronales Artificiales (ANN) o modelos de enfoque Bayesiano (Zumwald et al., 2021), (Shi et al., 2021), (Khalil et al., 2021) (McCarty et al., 2021). Estas técnicas se han empleado de manera asertiva para describir las complejas relaciones asociadas a la heterogeneidad de fuentes que alteran la LST. Sin embargo, es importante, en el contexto de la teledetección avanzar hacia algoritmos de aprendizaje automático explícitos, que hagan uso de conceptos geográficos ponderados para mejorar su precisión y superar los modelos de aprendizaje automático de propósito general.

### **2.1.1 Climatología urbana**

De acuerdo con el IPCC, (2013) el clima es la descripción de variables meteorológicas como temperatura, precipitación y viento, en términos de su media y variabilidad, para un área determinada en una ventana de tiempo, generalmente 30 años. Los cambios en plazos cortos son denominados variabilidad climática. Esta variabilidad en el área urbana se encuentra asociada a las alteraciones de las condiciones biofísicas, impulsadas por el crecimiento acelerado de la actividad humana y conducentes al forzamiento antropogénico. La urbanización es una de las fuerzas más importantes para impulsar la transformación económica del territorio (Almulhim et al., 2022). Sin embargo, representa un fenómeno continuo con muchas repercusiones ambientales. La emergencia climática es un desafío que no podemos desconocer como sociedad. Las ciudades son protagonistas de este desafío dado que aportan 70% de las emisiones globales de dióxido de carbono (Ozawa-Meida et al., 2021). Si bien el proceso de urbanización tiene implicaciones importantes para el desarrollo de las sociedades, la urbanización no planificada ejerce presiones directas que impactan

varios componentes ambientales, especialmente la temperatura superficial terrestre.

El entorno urbano se caracteriza por altas densidades de construcción que impermeabilizan el suelo, provocando un clima diferente comparado con el de sus áreas circundantes: *el clima urbano*. Debido a los impactos generalizados en la sociedad y en los ecosistemas naturales, la comprensión de la variabilidad climática urbana se ha convertido en una preocupación importante. La climatología urbana estudia los mecanismos de cambio que alteran las características físicas del paisaje en comparación con el entorno rural (Emilsson, 2021). Pareciera que la visión para ajustar nuestras ciudades a través de los planes de ordenación del territorio no ha dado los resultados esperados y los modelos convencionales resultan incompatibles con la heterogeneidad de los patrones de expansión y la conservación de los recursos naturales limitados. Esto conduce a una vida urbana incómoda, problemas de salud, y un aumento en el consumo energético. En general la relación entre la modificación antrópica del clima urbano y los modelos de ordenación del territorio es compleja y requiere una visión crítica de los enfoques de planificación urbana y desarrollo sostenible.

Las actuales condiciones climáticas planetarias exigen que las ciudades implementen estrategias para disminuir sus impactos y mejorar la adaptabilidad del sistema urbano creando soluciones autoregenerativas en la estructura urbana. Establecer vínculos entre el clima y otros objetivos de sostenibilidad es el fundamento del Acuerdo de París y los 17 *Objetivos de Desarrollo Sostenible* (ODS) de la Agenda 2030 de la ONU. Esto ha dado una visión mundial para diseñar ciudades sostenibles, saludables, y cómodas. Para lograrlo, es necesario disminuir la brecha entre la planificación territorial y la climatología urbana haciendo la transferencia del conocimiento científico a los entornos de planificación (Fallmann and Emeis, 2020). El enfoque de sostenibilidad del desarrollo urbano requiere de esfuerzos transdisciplinarios para comprender de mejor manera los mecanismos físicos de los climas urbanos y sus impactos en la salud humana. Estos mecanismos están compuestos por procesos de superficie y procesos atmosféricos. Los procesos de superficie incluyen la absorción de la radiación solar desde las distintas cubiertas urbanas, en interacción con la evapotranspiración y absorción del agua. Los procesos atmosféricos incluyen la

circulación del aire y la geometría urbana, que combinados hacen que se altere el movimiento vertical del aire caliente que se eleva y el frío que desciende.

Los Sistemas de Observación de la Tierra (EOS) son una tecnología que permite mapear y monitorear diferentes variables en consideración de los problemas de sostenibilidad del territorio. Por tanto, al centrarse en el monitoreo de la urbanización y la temperatura, los resultados pueden proporcionar una orientación cuantitativa y apoyo a la toma de decisiones para la mitigación del fenómeno SUHI y la planificación urbana sostenible, por ejemplo, produciendo el *Mapa Climático Urbano* (UCMap). Este concepto fue creado por el Profesor alemán Knoch en la década de 1950. El aporte a la planificación y desarrollo urbano del UCMap se ha convertido en un interés de investigación mundial desde la década de 1990, desde entonces, más de 15 países indicados en la [Figura 2](#), han formulado sus mapas climáticos ([Ren et al., 2011](#)), ([Liu et al., 2017](#)), ([Dang et al., 2023](#)).

El UCMap es una herramienta de información y evaluación para integrar los factores climáticos urbanos y las consideraciones urbanísticas. Tiene 2 componentes, el *Mapa de Análisis Climático Urbano* (UC-AnMap) y el *Mapa de Recomendaciones de Planificación Climática Urbana* (UC-ReMap) ([Ng and Ren, 2015](#)).



*Figura 2. Estudios UCMap alrededor del mundo*

Tomado de [Ren et al., \(2011\)](#).

El *Mapa de Análisis Climático Urbano* (UC-AnMap) emplea parámetros climáticos y datos de uso y cobertura del suelo para cuantificar las cargas térmicas y potencial dinámico, así como el impacto en el confort térmico, e

información de los vientos. La carga térmica se refiere a la intensidad de calor almacenado o emitido por zonas específicas. El potencial dinámico se centra en las variables que afectan el entorno del viento. [Ren et al., \(2011\)](#) proponen evaluar la función climática por unidades específicas que permitan a los planificadores diferenciar acciones a través de 5 *zonas de planificación climática urbana* (UCPZ) que contienen recomendaciones estratégicas expuestas en la [Tabla 1](#).

La evaluación de la función climática por zonas del UC-AnMap se desarrolla en el UC-ReMap. De acuerdo con modelos internacionales el *Mapa de Recomendaciones de Planificación Climática Urbana* (UC-ReMap) proporciona sugerencias basadas en análisis y evaluación de factores climáticos. El UC-ReMap presenta una evaluación espacial de las características climáticas urbanas actuales e identifica áreas climáticamente valiosas, problemáticas y sensibles que necesitan atención y mejora de la planificación estratégica. El UC-ReMap en sí mismo no es un instrumento regulatorio, pero, facilita el proceso de planificación participativa al proporcionar información climática urbana útil ([CUHK, 2011](#)).

*Tabla 1. Zonas de planificación climática*

Zona	Clase climática	Impacto al confort térmico	Acción de planificación estratégica
UCPZ-1 Zona climáticamente valiosa	Carga térmica negativa moderada y buen potencial dinámico	Enfriamiento moderado	Preservación
	Algo de carga térmica negativa y buen potencial dinámico	Enfriamiento ligero	
UCPZ-2 Zona neutra climáticamente sensible	Baja carga térmica y buen potencial dinámico	Neutro	Mantenimiento
	Algo de carga térmica y algo de potencial dinámico		
UCPZ-3 Zona moderadamente sensible	Carga térmica moderada y cierto potencial dinámico	Calentamiento moderado	Algunas acciones de mitigación fomentadas

Zona	Clase climática	Impacto al confort térmico	Acción de planificación estratégica
			cuando sea posible
UCPZ-4 Zona altamente sensible	Carga térmica moderadamente alta y potencial dinámico bajo	Calentamiento moderadamente fuerte	Acciones de mitigación recomendadas y necesarias
	Alta carga térmica y bajo potencial dinámico	Calentamiento fuerte	
UCPZ-5 Zona muy altamente sensible	Carga térmica muy alta y potencial dinámico bajo	Calentamiento muy fuerte	Acciones de mitigación recomendadas y esenciales

## 2.1.2 Plataformas satelitales empleadas para estimar LST

Los satélites de observación de la Tierra están equipados con instrumental científico, que registran información multispectral emitida y/o reflejada por las distintas coberturas de la superficie terrestre a diferentes resoluciones espectral, espacial y temporal. Estos sensores tienen la capacidad de medir radiación de onda corta (bandas espectrales no térmicas), y de onda larga (bandas térmicas). La teledetección térmica de la superficie urbana es un caso especial de observación de la LST, que varía en respuesta al balance de energía superficial (Voogt and Oke, 2003). Durante los últimos 40 años, las plataformas satelitales que llevan a bordo sensores de infrarrojo térmico (TIR) han sido una fuente determinante para el análisis y modelación de parámetros ambientales. Los TIRs permiten calcular la LST por lo que ofrecen gran potencial para investigar el fenómeno SUHI, mejorando la comprensión de la dinámica del clima urbano. Estos instrumentos proporcionan datos precisos para diferentes períodos de tiempo y resoluciones, aunque la presencia de nubes afecta seriamente los resultados y procesos comparativos.

Actualmente, diferentes sensores satelitales se emplean para monitorear LST. Entre los más populares se encuentran ASTER; MODIS; Landsat-TM, ETM+, TIRS, TIRS-2; y Sentinel-3 SLSTR. La [Tabla 2](#) describe las principales características de los satélites de cobertura global que se encuentran actualmente en funcionamiento. En general, el instrumental de alta resolución temporal proporciona mediciones con mayor frecuencia, pero, con menor resolución espacial, mientras que los instrumentos de mejor resolución espacial proporcionan mejor nivel de detalle, pero, con una menor frecuencia.

*Tabla 2. Sensores térmicos usados en estudios de LST.*

*Adaptada de Almeida et al., (2021).*

<b>Plataforma</b>	<b>Sensor</b>	<b>Resolución temporal</b>	<b>Resolución espacial</b>
National Oceanic and Atmospheric Administration (NOAA)	Advanced Very High-Resolution Radiometer (AVHRR)	2 veces al día	1 km
Terra	Moderate Resolution Imaging Spectroradiometer (MODIS)	2 veces al día	1 km
Aqua	Moderate Resolution Imaging Spectroradiometer (MODIS)	2 veces al día	1 km
ENVironmental SATellite (ENVISAT)	Advanced Along-Track Scanning Radiometer (AATSR)	35 días	1 km
Terra	Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)	16 días	90 m
Landsat-7	Enhanced Thematic Mapper Plus (ETM+)	16 días	60 m
Landsat-8	Operational Land Imager (OLI/TIRS)	16 días	100 m
Landsat-9	Operational Land Imager 2 (OLI-2/TIRS2)	16 días	100 m
Sentinel-3	SLSTR (Sea and Land Surface Temperature Radiometer)	2 días	500 m

La resolución espectral es una característica fundamental de los sensores térmicos, ya que determina su capacidad para detectar diferencias sutiles en la radiación emitida por la Tierra a diversas longitudes de onda. La [Tabla 3](#) señala

el número de bandas térmicas, rangos y resolución espectral de los sensores mayormente empleados para derivar la LST. La capacidad de un sensor para distinguir entre diferentes materiales o cubiertas de la superficie de la Tierra se ve afectada por su resolución espectral. Cada sensor tiene características únicas en términos de su resolución espacial, sensibilidad térmica, frecuencia de muestreo y otros factores que influyen en su rendimiento. La elección del sensor adecuado para una aplicación particular dependerá de los requisitos específicos de la aplicación en términos de resolución espacial y espectral, cobertura temporal y otros factores. Los sensores térmicos modernos, como el SLSTR y el OLI-2/TIRS2, tienen una mejor resolución espacial y temporal, precisión radiométrica y capacidad de detección en comparación con los sensores más antiguos, como el AVHRR y el ETM+. Además, los sensores más nuevos tienen una mayor frecuencia de muestreo y capacidad de detectar radiación térmica a través de niebla, lo que los hace más adecuados para aplicaciones de vigilancia ambiental y detección de incendios.

*Tabla 3. Resolución espectral de sensores térmicos*

<b>Plataforma/sensor</b>	<b>Bandas y rangos espectrales (<math>\mu\text{m}</math>)</b>	<b>Resolución espectral (<math>\mu\text{m}</math>)</b>
NOAA/ AVHRR	Banda 3 (Ventana central): 3,55 – 3,93	0,10
	Banda 4 (infrarrojo cercano): 3,55 – 3,93	0,10
	Banda 5: (infrarrojo medio): 11,5 – 12,5	0,10
Terra-Aqua/ MODIS	Banda 31: 10,780 – 11,280	0,64
	Banda 32: 11,770 – 12,270	0,62
ENVISAT/ AATSR	Banda 5: 10,85 – 11,65	0,02
	Banda 6: 11,50 – 12,50	0,02
Terra/ ASTER	Banda 10: 8,125 – 8,475	0,10
	Banda 11: 8,475 – 8,825	0,10
	Banda 12: 8,925 – 9,275	0,10
	Banda 13: 10,250 – 10,950	0,15
	Banda 14: 10,950 – 11,650	0,15
Landsat-7/ ETM+	Banda 6 (banda térmica): 10,4 – 12,0	0,10
Landsat-8/ OLI/TIRS	Banda 10: 10,6 – 11,35	0,10
	Banda 11: 11,30 – 12,30	0,10
Landsat-9/ OLI-2/TIRS2	Banda 11: 10,6 – 11,35	0,10
	Banda 12: 10,90 – 12,10	0,10
Sentinel-3/ SLSTR	Banda 10: 8,4 – 9,5	0,05
	Banda 11: 10,5 – 12,4	0,05

Plataforma/sensor	Bandas y rangos espectrales ( $\mu\text{m}$ )	Resolución espectral ( $\mu\text{m}$ )
	Banda 12: 3,55 – 3,95	0,05
	Banda 13: 3,75 – 4,05	0,05

### 2.1.3 Escalas para analizar SUHI

Las SUHI son consecuencia de la combinación de diversos fenómenos que suceden a diferentes escalas. Por un lado, las actividades humanas en zonas urbanas como el tráfico, la industria, la construcción y el consumo energético, generan calor antropogénico que se acumula en el ambiente. Por otro lado, la configuración de la ciudad modifica el balance energético y la circulación del aire, aumentando la temperatura local. La escala es un parámetro que da forma a los fenómenos geográficos y define los límites en sus observaciones. La discrepancia entre escalas puede llevar a diferentes conclusiones en los procesos de monitoreo y pronóstico, sin embargo, no existe una forma factible de considerar los procesos de formación SUHI a todas las escalas simultáneamente, debido a las limitaciones teóricas para describir el fenómeno en cada una de ellas (Wu and Li, 2009) (Zhou et al., 2019b). Los procesos que afectan el ambiente térmico urbano operan a diferentes niveles climáticos que analizan el fenómeno a distintos niveles de detalle, generalmente se reconocen 3 de ellos representados en la Figura 3, mesoescala, escala local y microescala.

La *Mesoescala*, implementa campos de la meteorología y climatología urbana, por ejemplo, la ventilación geostrofica y la dispersión de contaminantes (Mirzaei and Haghghat, 2010). La resolución va del orden de kilómetros y sus modelos se basan en ecuaciones de mecánica de fluidos (Mirzaei, 2015). La *Escala local*, modela el fenómeno SUHI de ciudades a través de técnicas de teledetección para recuperar la LST y obtener información del uso y cobertura del suelo que se analizan bajo diversos modelos estadísticos. La *Microescala*, tipifica los microclimas urbanos bajo las dimensiones de edificios individuales, árboles, caminos, calles, patios, y jardines. En esta escala se pueden detectar patrones de temperatura muy precisos en áreas muy pequeñas (Chang et al., 2021).

En el contexto del fenómeno SUHI existen 3 capas importantes en la atmósfera que se encuentran estrechamente relacionadas, la capa superficial, la

capa de límite urbano, y la capa de límite atmosférico. La [Figura 3](#) enseña la estratificación vertical de la atmósfera urbana.

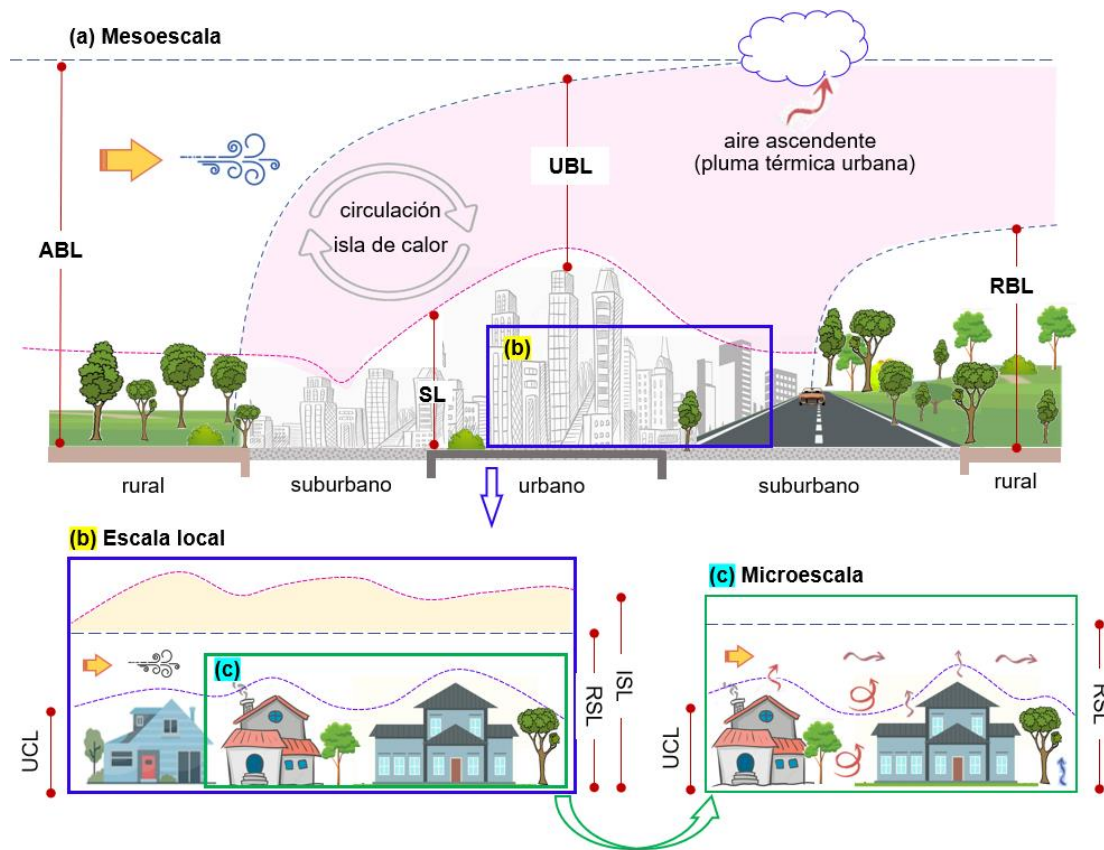


Figura 3. Escalas empleadas en estudios térmicos.

Tomada y adaptada de (Oke, 2006). ABL: capa de límite atmosférico (la capa más baja de la atmósfera); UBL: capa límite urbana; RBL: capa límite rural; SL: capa superficial; ISL: subcapa inercial; RSL: subcapa de rugosidad; UCL: capa de dosel urbano.

La *capa superficial* (SL) es la más cercana a la superficie terrestre y está compuesta por las *subcapas de rugosidad* (RSL) e *inercial* (ISL). En la RSL, la rugosidad se entiende como la medida de cantidad de obstáculos presentes en la superficie que causan impacto en la dirección y velocidad del viento. En la ISL la circulación del aire se encuentra influenciada por la inercia del aire y la rotación terrestre.

En la *capa de límite urbano* (UBL) se mezclan los intercambios de la superficie urbana con la atmósfera ocasionando la circulación de la isla de calor transportada a través del viento. Esta parte de la atmósfera vincula la escalas local

y micro, reflejando los efectos que la superficie introduce a la estructura de la *capa de límite atmosférico* (ABL) (Núñez Peiró et al., 2019).

La *subcapa inercial* es el nivel en que la atmósfera se ha ajustado al paisaje urbano subyacente, de modo que los flujos de energía allí presentes son representativos del microclima creados por jardines, techos, y paredes que componen un vecindario a escala local. Los elementos dentro de la *subcapa de rugosidad* están expuestos a los efectos microclimáticos individuales (Mills, 2014).

#### 2.1.4 Técnicas para la estimación del fenómeno

En general, el fenómeno SUHI se ha definido como la diferencia media entre la LST de las áreas urbana y rural. Los límites de las ciudades usualmente son imprecisos, dado que la continuidad urbana y los procesos de expansión generan espacios de transición hacia usos del suelo rural. Hasta el momento frente a la caracterización del fenómeno SUHI, no hay claridad en la literatura para la definición de estas áreas que terminan fijándose por condiciones propias locales.

La intensidad térmica urbana se hace cambiante en función de la amplitud rural definida para hacer el cálculo. Es posible que, al fijar el límite rural en un perímetro cercano a la zona urbana, el modelo genere sobreestimaciones debido a la actividad antrópica suburbana. En caso contrario, de fijarse muy alejado se podrían presentar subestimaciones asociadas a la alta cantidad de píxeles con registros de bajas temperaturas. No existe un modelo estandarizado para la medición de SUHI y esto genera limitaciones para analizar el fenómeno entre ciudades (Martin-Vide et al., 2015).

Autores como Mohammad et al., (2019), Hassan et al., (2021) y Athukorala and Murayama, (2021) analizaron el fenómeno SUHI en diferentes ciudades definiendo las fronteras rurales a través de zonas de influencia (*buffers*) con distancias variables que van desde 1 hasta 25 km. Peng et al., (2012) estudiaron el fenómeno en 419 ciudades y definieron que el área de influencia es 150% del área urbana. Otros investigadores como Li et al., (2021) utilizaron los límites administrativos de las ciudades como frontera de análisis, lo cual tiene la ventaja de contrastar sus resultados con los datos socioeconómicos del territorio.

[Schwarz et al., \(2011\)](#) compararon 11 métodos propuestos por distintos autores en diferentes tiempos para cuantificar SUHI en 263 ciudades europeas, al aplicarlos simultáneamente solo algunos modelos pudieron tener alta correlación. [Qiao et al., \(2019\)](#) y [Yao et al., \(2021\)](#) calcularon un índice conocido como la huella del efecto SUHI. Este cuantifica el área térmica afectada a través de una superficie gaussiana bidimensional. La suposición de que los datos presentan comportamiento gaussiano no siempre está presente en los factores determinantes de LST ([Yang et al., 2019](#)). [Sobrino and Irakulis, \(2020\)](#) propusieron un modelo para calcular y comprar SUHI en aglomeraciones urbanas definiendo 3 referencias de entorno dependientes exclusivamente del núcleo urbano, superando el sesgo que supone la definición de las áreas urbana y rural.

Otro enfoque del fenómeno SUHI es el empleado por autores como [Wang et al., \(2017\)](#), [Wu et al., \(2019\)](#) y [Nadizadeh Shorabeh et al., \(2020\)](#), que obtienen la LST urbana desde sensores satelitales, para investigar la variación espacial térmica y su mecanismo evolutivo en partes especialmente calientes al interior de las ciudades, utilizando escalas de clasificación térmica derivadas de la LST media y su desviación estándar. Este enfoque es el empleado en este trabajo.

Un modelo que se ha utilizado para caracterizar las temperaturas del aire en áreas urbanas (UHI), y que se plantea como una alternativa eficiente en zonas con baja disponibilidad de imágenes satelitales por condiciones de nubosidad, es la observación directa a través de transectos móviles ([Yokoyama et al., 2018](#)), ([C. Y. Sun et al., 2019](#)), ([Romero Rodríguez et al., 2020](#)). Este método utiliza una plataforma móvil como una bicicleta, donde se instalan un sensor térmico y un sistema de navegación satelital que obtienen múltiples registros de temperatura y ubicación en lapsos de tiempo cortos, a lo largo de los transectos previamente diseñados. Los registros térmicos necesitarán de un ajuste por sincronización de tiempo ([Huang et al., 2020](#)).

## 2.1.5 Factores influyentes

Se ha demostrado que los patrones de distribución y las tendencias del calentamiento urbano vienen definidos por una variedad de factores, no siempre los mismos para todas las ciudades, que son cambiantes según su ubicación geográfica y las estaciones climáticas del año (Bechtel et al., 2019) (Li et al., 2021). Las diferentes características físicas de la superficie como la ausencia de espacios verdes, las grandes extensiones de hormigón y asfalto, que emiten calor antropogénico a la atmósfera y que junto con el material particulado en suspensión y la huella de carbono de la ciudad realizan una sobrecarga al ozono troposférico, se convierten en los responsables del exceso de calor que se registra en las zonas urbanas frente a las rurales. El fenómeno SUHI es un sistema complejo que se genera como el resultado de la interacción de diversos factores dinámicos influyentes, provocando un efecto de desequilibrio térmico urbano en sus dimensiones espaciotemporales. La estructura heterogénea del sistema urbano genera esta interactividad como producto de sus efectos antrópicos. Esto sugiere la necesidad de su caracterización, como una expresión fundamental entre causas y efectos de los ecosistemas urbanos, que permita transitar hacia un desarrollo sostenible en términos de adaptación y toma de decisiones con soporte científico.

Las propiedades físicas de las cubiertas terrestres influyen en LST y, por tanto, en las SUHI. La reducción en las cubiertas naturales, la expansión del suelo urbano y la intensificación de las actividades humanas provocan la alteración de las características físicas superficiales acelerando la acumulación de calor y contribuyendo a su aumento significativo (Dutta et al., 2021). La urbanización ha provocado una transformación en la composición y estructura de LULC. El aporte de energía por radiación solar aumenta si se elimina y reemplaza la vegetación por superficies impermeables. La deforestación y las transiciones espaciales hacia proyectos de desarrollo generan presiones humanas sobre el ecosistema que han resultado en la disminución de la cubierta vegetal. Esta pérdida tiene implicaciones de gran alcance, dado que la vegetación enfría el área circundante como consecuencia de la evapotranspiración, regulando el intercambio de flujo de calor latente y la reducción de calor sensible (Kaiser et al.,

2022). Además, la vegetación densa disminuye la LST ya que las copas de los árboles y su sombra reducen la irradiancia solar directa.

El aumento de las superficies impermeables produce un incremento en LST que depende en gran medida de la inercia y conductividad térmica de la superficie. Los materiales de mayor conductividad transfieren más fácilmente energía térmica hacia su interior, mientras que los materiales con alta capacidad calorífica almacenan más calor y, cuanto más calor retienen, mayor es su temperatura (Ayanlade et al., 2021). Según Vujovic et al., (2021) el aumento de las temperaturas como producto de los tejidos urbanos se encuentra vinculado con las propiedades de los materiales de construcción, ya que estos retienen un enorme flujo de calor acumulado. La mayor parte de las superficies impermeables urbanas como las carreteras, andenes y tejados de las viviendas, están construidas con asfalto, hormigón y cemento, estos materiales exhiben un alto grado de inercia térmica y poseen propiedades de alta absorción calórica. El asfalto, por ejemplo, absorbe el 95% de la luz solar. En la radiación solar, suele haber un 43% de energía solar, 52% de luz infrarroja cercana y 5% de luz ultravioleta, y un gran porcentaje de estas es absorbida y retenida por la superficie asfáltica (Le et al., 2020).

La LST no solo está relacionada con los atributos espectrales de las áreas construidas como las propiedades térmicas de los materiales de construcción, sino también, con el entorno circundante de la composición del dosel urbano (Song et al., 2020). La forma urbana se refiere a la forma física de los desarrollos que facilitan las actividades humanas y sus interacciones. Distintos investigadores han hallado relaciones potenciales entre las formas urbanas 2D/3D y LST (Y. Sun et al., 2019). La composición de la estructura urbana modifica la intensidad de SUHI porque influye en el intercambio energético entre la superficie terrestre, la superficie de las edificaciones y la atmósfera baja, afectando el proceso de absorción de radiación solar y la emisión de radiación de onda larga superficial, conllevando a la acumulación de calor en las zonas urbanas (Yu et al., 2021), (Chen et al., 2021).

El flujo de calor antropogénico es uno de los principales contribuyentes a la formación de SUHI. Se trata del volumen de calor liberado a la atmósfera

generado por las actividades humanas. Este proviene de diversas fuentes incluidas áreas comerciales, residenciales, industriales, volumen de tráfico y consumo energético (Firozjaei et al., 2020). Dado que las actividades humanas son espacialmente heterogéneas, las emisiones de calor antropogénico difieren con respecto a las zonas funcionales urbanas que están estrechamente relacionadas con el uso del suelo (Lu et al., 2021). Los factores climáticos como temperatura, precipitación, humedad y velocidad del viento, afectan de manera directa el balance energético entre áreas rurales y urbanas (Z. Wang et al., 2022). La presencia de nubes disminuye el efecto térmico por su influencia sobre la cantidad de irradiancia solar que llega a la superficie (Romero Rodríguez et al., 2020). U.S. Environmental Protection Agency, (2008) definió 6 factores determinantes sobre el fenómeno entre los que se incluyen:

- la reducción de la vegetación en áreas urbanas,
- las propiedades de los materiales de construcción,
- la geometría urbana,
- las emisiones de calor antropogénico,
- el clima,
- la ubicación geográfica.

También, diversas condiciones socioeconómicas como, densidad poblacional, producto interno bruto, e índice de iluminación nocturna, han sido tratadas considerablemente y con alto grado de correlación en diferentes estudios (Zhi et al., 2020), (W. Liu et al., 2021). Investigaciones recientes han asociado al fenómeno elementos de la composición del paisaje, representados como una porción de las distintas cubiertas del suelo en función de sus reflectancias y propiedades térmicas (Xiang et al., 2021), (Q. Wang et al., 2022). En general, los factores asociados al fenómeno SUHI se pueden agrupar en 4 categorías señaladas en la **Figura 4**: factores ambientales (usualmente representados por diversos índices espectrales), condiciones climáticas (como precipitación y velocidad de los vientos), indicadores del paisaje e indicadores socioeconómicos.



*Figura 4. Factores impulsores contribuyentes a la isla de calor urbano superficial*

La variabilidad de los descriptores de la LST de una ciudad a otra se debe a la combinación de factores ambientales, humanos y estructurales de cada ciudad que influyen en distintas proporciones. El conocimiento de sus contribuciones ponderadas permite comprender las causas subyacentes de las variaciones en áreas urbanizadas, para desarrollar estrategias efectivas y adaptadas a las características específicas de la ciudad y mitigar los efectos negativos sobre el medio ambiente y la salud de sus pobladores.

## **2.2 Interacción de la radiación con la atmósfera y la superficie terrestre**

La teledetección suministra información crítica sobre cómo la energía solar se distribuye en los sistemas naturales y artificiales. La radiación electromagnética (REM) es el proceso responsable de la transferencia de energía en la atmósfera, y desempeña un papel principal en el sistema climático de la Tierra a través del balance de energía superficial. Esta transferencia incluye fenómenos de dispersión y absorción que implican moléculas, aerosoles y partículas de nubes, así como la reflexión y la emisión superficial (Galanaki et al., 2021). Estas

interacciones son complejas y varían en función de la longitud de onda de la radiación, así como de las características de la superficie y la atmósfera. La cantidad de radiación reflejada depende de la reflectividad superficial (albedo). Las superficies brillantes como la nieve, hielo y nubes poseen un alto albedo, lo que implica que reflejan la mayor parte de la radiación solar incidente. Las superficies oscuras como el agua y la vegetación, tiene albedo bajo, por lo cual absorben mayor cantidad de radiación solar.

Para que la irradiancia solar ( $E_0$ ) alcance la superficie de la Tierra deberá atravesar la atmósfera. Las partículas y los gases allí presentes afectan gran parte de la radiación entrante, pero, en condiciones de cielo despejado la radiación puede llegar al sensor después de una reflexión directa como la señalada por la ruta ① de la [Figura 5](#) (Tomada y adaptada de [Jensen, \(2007\)](#)). En este caso, la irradiancia que llega a la superficie está en función de la transmitancia atmosférica a través del ángulo ( $T_{\theta_0}$ ), y la cual deberá ser corregida por el ángulo cenital solar ( $\theta_0$ ). Los efectos atmosféricos que actúan sobre la radiancia son principalmente causados por los fenómenos de dispersión y absorción. Las longitudes de onda del espectro visible e infrarrojo cercano son afectadas por la dispersión a causa de la interacción entre moléculas de gas y aerosoles con la radiación solar, ocasionando su cambio de dirección hacia el sensor sin alcanzar la superficie terrestre, como aparece en la ruta ②. Este efecto es particularmente severo en el extremo azul del espectro visible ( $0,4 \mu\text{m}$ ) ocasionando una apariencia de bruma, que disminuye el contraste y nivel de detalle en la imagen. Hay 3 tipos de dispersión allí presentes la de Rayleigh, Mie, y la no selectiva.

La dispersión de Rayleigh es causada por 2 factores fundamentales. El primero, la dispersión de la radiancia producida por partículas de nitrógeno u oxígeno y moléculas de polvo presentes en la atmósfera de menor diámetro que la longitud de onda de la radiación con que interactúa. Y el segundo, por la reflexión especular de la luz dispersada atmosféricamente (luz del cielo) de la superficie del mar. El efecto de la dispersión de Rayleigh es inversamente proporcional a la cuarta potencia de la longitud de onda ( $\lambda^{-4}$ ), entonces, la luz azul ( $0,4 \mu\text{m}$ ) se dispersa 16 veces más que la luz infrarroja cercana ( $0,8 \mu\text{m}$ ), por tanto, las longitudes de onda de energía más corta se dispersan más que las longitudes de onda largas ([Seasholtz et al., 1997](#)). Esta dispersión presenta el

mayor impacto en la corrección de la reflectancia por efectos atmosféricos, ocupando cerca del 80% de la radiancia producida a lo largo de su camino óptico (Chen and Feng, 2018).




Figura 5. Influencia de la atmósfera en la medición de energía captada por el sensor

El color azul del cielo es una manifestación de la dispersión de Rayleigh. Sin el fenómeno de dispersión el cielo luciría negro. Pero, a medida que la luz solar interactúa con la atmósfera, dispersa a las longitudes de onda más cortas (azules) de forma más predominante que las otras longitudes de onda visibles (Lillesand et al., 2004). En consecuencia, vemos el cielo de color azul. Sin embargo, al amanecer y al atardecer, los rayos del Sol recorren una trayectoria atmosférica más larga que durante el mediodía. Con el camino más largo, la dispersión de las longitudes de onda cortas es tan completa que solo percibimos las longitudes de

onda más largas y menos dispersas de colores naranja y rojo (Lillesand et al., 2004). La dispersión de Mie tiene lugar cuando hay partículas esencialmente esféricas presentes en la atmósfera con diámetros aproximadamente iguales a la longitud de onda de la radiación. Las partículas de vapor de agua, y el polvo son los principales agentes de dispersión en la luz visible. La cantidad de dispersión es mayor que la de Rayleigh y las longitudes de onda dispersadas son más largas. Este fenómeno se presenta mayoritariamente en las capas inferiores de la atmósfera, donde, se presentan partículas de tamaño considerables que van desde décimas de micrómetro hasta varios micrómetros de diámetro (Jensen, 2007).

La contaminación también contribuye a hermosos amaneceres y atardeceres. Cuanto mayor sea la cantidad de partículas de humo y polvo en la columna atmosférica, más luz violeta y azul se dispersará y solo la luz de las longitudes de onda del naranja y rojo llegarán a nuestros ojos. Por su parte, la dispersión no selectiva se produce cuando hay partículas de agua en suspensión de mayor tamaño que el diámetro de la radiación que se transmite. Aquí se dispersan todas las longitudes de onda de la luz, más o menos por igual, lo que hace que veamos las nubes y neblina en color blanco (Jensen, 2007). La dispersión puede reducir severamente el contenido de información de los datos de sensores remotos, al punto de que las imágenes pierden contraste y es complicado diferenciar entre objetos.

La ruta ③ contiene energía del Sol que ha sido afectada por dispersiones de Rayleigh, Mie y/o no selectiva, además, de algunos procesos de absorción antes de iluminar el objeto de estudio. Su composición espectral puede ser ligeramente distinta a la energía que proviene de la ruta ①. La ruta ④ contiene radiación que se refleja o dispersa por las diferentes cubiertas cercanas al objeto de estudio. La ruta ⑤, es energía que también se reflejó desde una cobertura cercana hacia la atmósfera, pero, luego se dispersó o se reflejó en el objeto de estudio. La energía almacenada de las rutas ② y ④ se conoce como radiancia ‘trayectoria’ ( $L_P$ ). La ( $L_T$ ) es radiancia devuelta del objeto de estudio, por lo tanto, la radiancia que alcanza el sensor ( $L_{TOA}$ ) está definida por la Ecuación 2 en Jensen, (2007):

$$L_{TOA} = L_T + L_P \quad (2)$$

En contraste con la dispersión, el fenómeno de absorción se da como el resultado de la pérdida de energía en interacción con los constituyentes atmosféricos. La radiación solar al atravesar la atmósfera absorbe parcialmente moléculas de ozono ( $O_3$ ), dióxido de carbono ( $CO_2$ ) y vapor de agua ( $H_2O$ ) comportándose como un filtro selectivo. La fuerza de la absorción depende en gran medida de la longitud de onda, ya que sucede cuando la radiación tiene una longitud de onda similar a la frecuencia del gas que realiza la absorción, que a su vez dependerá de su estructura molecular.

El  $O_3$  absorbe la radiación ultravioleta del Sol en la atmósfera alta. El  $CO_2$  absorbe la radiación en los infrarrojos medio y lejano. Esta área es asociada con el aumento térmico manteniendo el calor dentro de la atmósfera inferior. El vapor de agua en la atmósfera absorbe gran parte de la radiación entrante de microondas de onda corta e infrarroja de onda larga (entre  $27 \mu m$  y  $1 m$ ). Los intervalos de longitudes de onda donde no se producen los mecanismos de absorción se llaman ventanas atmosféricas, y transmiten la energía incidente de manera efectiva al suelo ([National Weather Service, 2020](#)). Los sistemas de teledetección operan dentro de estas ventanas. Las bandas térmicas se hallan en regiones del espectro electromagnético donde la atmósfera es relativamente transparente a la radiación, permitiendo una medición precisa de temperatura superficial.

Las fuentes primarias de energía más comunes son la energía solar y la radiación emitida desde la Tierra. En la [Figura 6](#) (tomada y adaptada de [National Weather Service, \(2020\)](#)), al comparar estas fuentes con las ventanas atmosféricas disponibles, se pueden comprender la interdependencia entre las fuentes primarias de energía y la sensibilidad espectral de los sensores para detectar la energía de forma efectiva.

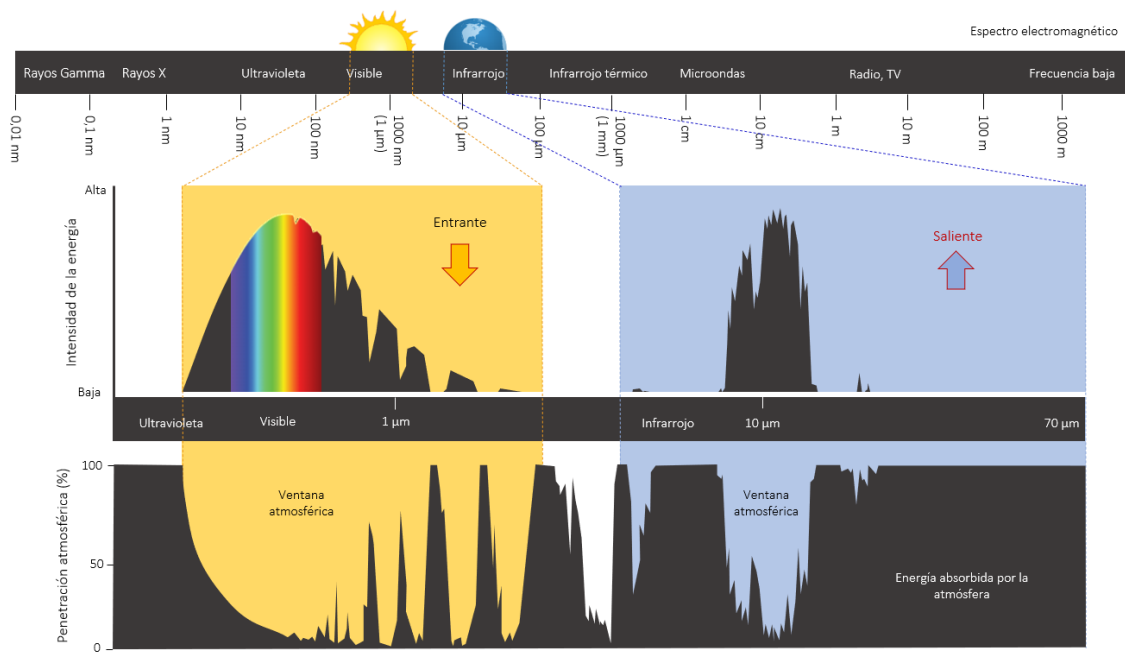


Figura 6. Características espectrales de la transmitancia atmosférica

## 2.3 Estimación de LST desde sensores remotos

Los datos registrados por sensores remotos en el dominio espectral del infrarrojo térmico cuantifican la radiancia de onda larga (8-14  $\mu\text{m}$ ) en la parte superior de la atmósfera (TOA), principalmente desde la radiación emitida del suelo. Esta señal es atenuada por las radiancias ascendente y descendente emitidas por el vapor de agua y los aerosoles presentes en la atmósfera, que son altamente variables en concentración y distribución dificultando su modelación (Tomlinson et al., 2011). Minimizar estos efectos es fundamental para utilizar las imágenes de banda térmica en estudios de LST.

La emisividad es una propiedad espectral de la materia que describe la eficiencia con la que un objeto emite radiación electromagnética en función de su temperatura (Langsdale et al., 2020). Se mide en el rango  $0 \leq \epsilon \leq 1$ , es adimensional, y se define como la relación entre la energía radiante desde la superficie de un objeto y la radiante desde un emisor perfecto conocido como cuerpo negro, a la misma temperatura, longitud de onda y bajo las mismas condiciones. El cuerpo negro que es un absorbedor ideal de energía es también un emisor ideal ( $\epsilon=1$ ). Un

error de 1% en la estimación de la emisividad puede conducir a errores de 1 K en la recuperación de LST (Vanhellemont, 2020). De acuerdo con la Ecuación de Transferencia Radiativa (RTE) la radiancia del cuerpo negro se expresa a través de la Ecuación 3:

$$B_i(T_s) = \frac{L_i^{\text{sen}} - L_i^{\uparrow}(\theta)}{\tau_i(\theta) \cdot \varepsilon_i} - \frac{1 - \varepsilon_i}{\varepsilon_i} \cdot L_i^{\downarrow} \quad (3)$$

$B_i(T_s)$  es la radiancia del cuerpo negro del canal  $i$ ,  $L_i^{\text{sen}}$  es la radiancia en sensor del canal  $i$ ,  $\theta$  es el ángulo de visión cenital,  $\varepsilon_i$  es la emisividad superficial,  $\tau_i(\theta)$  y  $L_i^{\uparrow}(\theta)$  son la transmisividad y la radiación atmosférica ascendente del canal  $i$  asociadas al ángulo  $\theta$ , y  $L_i^{\downarrow}$  es la irradiancia atmosférica descendente del canal  $i$ .

La Ley de Planck describe la relación entre la temperatura de la superficie y la radiación espectral emitida por el cuerpo negro. La temperatura del cuerpo negro también es conocida como temperatura de brillo (Vlassova, 2016). Dado que los objetos sobre la cubierta terrestre no son emisores perfectos no se comportan como cuerpos negros, por tanto, es necesario conocer su emisividad. La temperatura de brillo  $B(\lambda, T)$  se obtiene empleando la radiancia TOA a través de inversión de la Ley de Planck en la Ecuación 4, que sustenta que la cantidad de energía emitida por una superficie se encuentra directamente relacionada con su temperatura (Avraham et al., 2022). La radiancia espectral  $R(\lambda, T)$  de un cuerpo no negro emitida a una longitud de onda  $\lambda$  ( $\mu\text{m}$ ) a temperatura  $T$  (K), viene dada por la emisividad espectral  $\varepsilon(\lambda)$  multiplicada por la función de radiación de Planck (Dash, 2005).

$$R(\lambda, T) = \varepsilon(\lambda) \cdot B(\lambda, T) = \varepsilon(\lambda) \cdot \frac{C_1 \cdot \lambda^{-5}}{\pi \cdot \left[ \exp\left(\frac{C_2}{\lambda T}\right) - 1 \right]} \quad (4)$$

$C_1$  y  $C_2$  son constantes físicas,  $C_1 = 2 \cdot \pi \cdot h \cdot c^2 = 3,7418 \cdot 10^{-16} \text{ W} \cdot \text{m}^2$ ,  $C_2 = h \cdot c / k = 1,4388 \cdot 10^{-2} \text{ mK}$ ,  $h$  es la constante de Planck ( $6,626076 \cdot 10^{-34} \text{ Js}$ ),  $c$  es la velocidad de

la luz ( $2,99792458 \cdot 10^8 \text{ m} \cdot \text{s}^{-1}$ ),  $k$  es la constante de Boltzmann ( $1,380658 \cdot 10^{-23} \text{ JK}^{-1}$ ), las unidades de las radiancias espectrales son  $\text{W} \cdot \text{m}^{-2} \cdot \mu\text{m}^{-1} \cdot \text{sr}^{-1}$ .

Dado que la emisividad y los efectos atmosféricos de absorción y atenuación son fundamentales para obtener valores precisos de LST, se hace complejo obtener una solución analítica debido a las perturbaciones derivadas de los acoples temperatura/emisividad y absorción-emisión/reflexión superficial. Además, como la emisividad producida por la heterogeneidad de las cubiertas es diferente de 1, genera disminución de la radiación emitida. Y se complica aún más porque, la anisotropía de la reflectancia puede reducir o aumentar la radiación total superficial (Li et al., 2013b). La separación directa entre la temperatura y la radiancia superficial es inviable debido a la indeterminación causada por un sensor con  $N$  canales espectrales, dado que existen  $N$  mediciones, pero,  $N+1$  incógnitas, es decir,  $N$  emisividades espectrales más la temperatura superficial (Dash, 2005) Luego, el problema de la temperatura y la emisividad se resuelve utilizando una restricción adicional para recuperar la temperatura de la superficie y la emisividad de los datos registrados por los sensores remotos (Marcq et al., 2023). Para resolver este problema, se han desarrollado diferentes algoritmos con 3 enfoques generales: métodos monocanal, multicanal y multiángulo.

Los sensores que registran valores de radiancia a través de un solo canal son los llamados monocanal. Estos han sido desarrollados por diversos académicos que de acuerdo al tipo de sensor y área de investigación han propuesto diferentes algoritmos con mejoras constantes (Hook et al., 1992), (Sobrino et al., 1996), (Qin et al., 2001), (Jiménez-Munoz and Sobrino, 2003), (Cristóbal et al., 2009), (Jiménez-Muñoz et al., 2009), (Chen et al., 2015), (Wang et al., 2016). De forma generalizada en los modelos monocanal, la corrección de la atenuación atmosférica se logra a través de la RTE que requiere perfiles atmosféricos como datos de entrada (Galve et al., 2008). Estos perfiles se obtienen lanzando radiosondas en el área de estudio de manera simultánea con el paso del satélite. A menudo, estos registros no se encuentran disponibles y han sido un inconveniente de este modelo. Estos algoritmos necesitan de entradas específicas como emisividad, vapor de agua y temperatura atmosférica media. Dada la complejidad para su obtención, estas variables se han derivado desde imágenes multiespectrales. Por ejemplo, el alto

nivel de correlación entre la emisividad y el NDVI hace que muchos métodos para su estimación se apoyen en este índice espectral (Vlassova et al., 2014). Así mismo, los datos de emisividad del producto ASTER-GEDv3 han sido ampliamente considerados (Hulley et al., 2015). También, los productos atmosféricos recuperados de MODIS están disponibles para aplicar estas correcciones (Chen et al., 2011). Como alternativa para la serie de satélites Landsat Barsi et al., (2005) han desarrollado una calculadora de parámetros de corrección atmosférica, disponible en: <https://atmcorr.gsfc.nasa.gov/>. Esta emplea simulaciones de transferencia radiativa y perfiles atmosféricos de temperatura y humedad relativa estimando la transmisividad ( $\tau$ ) y radiancias ascendente ( $L_{\lambda\uparrow}$ ) y descendente ( $L_{\lambda\downarrow}$ ), para obtener la radiancia espectral medida por el instrumento al tope de la atmósfera de la correspondiente banda TIR ( $L_{TOA\lambda}$ ). Esto se hace en función de la radiancia en el espectro térmico ( $L_T$ ) y la emisividad espectral ( $\varepsilon$ ) empleando la Ecuación 5, para el momento y lugar del registro de la imagen. Las unidades de  $L_{\lambda\uparrow}$ ,  $L_{\lambda\downarrow}$  y  $L_{TOA\lambda}$  son  $W \cdot m^{-2} \cdot \mu m^{-1} \cdot sr^{-1}$ . La  $\varepsilon$  y  $\tau$  son adimensionales.

$$L_{TOA\lambda} = \tau \cdot \varepsilon \cdot L_{T\lambda} + L_{\lambda\uparrow} + \tau \cdot (1 - \varepsilon) \cdot L_{\lambda\downarrow} \quad (5)$$

Luego, la radiación emitida por un cuerpo negro a una temperatura  $L_{T\lambda}$  viene dada por la inversión de la Ecuación 5:

$$L_{T\lambda} = \frac{L_{TOA\lambda} - L_{\lambda\uparrow} - \tau \cdot (1 - \varepsilon) \cdot L_{\lambda\downarrow}}{\tau \cdot \varepsilon} \quad (6)$$

Finalmente, la LST es recuperada invirtiendo la Ley de Planck en la Ecuación 6.

$$LST = \frac{k_2}{\ln\left(\frac{k_1}{L_{T\lambda}} + 1\right)} \quad (7)$$

En esta ecuación,  $k_1$ , y  $k_2$  corresponden a las constantes de calibración del sensor disponibles en los metadatos de la imagen.

El segundo enfoque, el método multicanal, también llamado de ventana dividida emplea 2 bandas TIR ubicadas entre los 10 y 12  $\mu\text{m}$ . El principio básico de este método señala que la atenuación atmosférica experimentada por la radiancia emitida desde la superficie terrestre, es proporcional a la diferencia de radiación de las mediciones simultáneas en 2 canales térmicos (Jiménez-Muñoz et al., 2014). Esto quiere decir que a una temperatura determinada se presenta una relación lineal entre radiancia y temperatura, por lo que la radiancia se puede sustituir por una relación lineal para reducir el número de incógnitas desconocidas. Luego, cuando los datos satelitales tienen 2 o más canales TIR con diferentes transmitancias y emisividades, se pueden establecer al menos 2 ecuaciones para describir el proceso de transferencia de radiación de calor en la superficie terrestre. Finalmente, se elimina la incógnita desconocida que es la temperatura promedio de la radiación ascendente de la atmósfera, y se simplifica la RTE para recuperar la LST (H. Wang et al., 2019). Este método fue desarrollado por McMillin, (1975) para estimar la temperatura de la superficie del mar. Desde entonces, una gran variedad de algoritmos de ventana dividida se han desarrollado para obtener temperatura superficial desde Aqua/MODIS (Brown et al., 1999), Terra/MODIS (Mao et al., 2005), Terra/ASTER (Wang and He, 2014), Landsat 8/TIRS (Jiménez-Muñoz et al., 2014), Landsat 9/TIRS (Ye et al., 2022).

El tercer enfoque, el método multiángulo, se basa en la absorción atmosférica diferencial empleando varios ángulos de visión y, por tanto, diferentes longitudes de trayectoria para reducir el efecto del vapor de agua atmosférico sobre LST. Al igual que el modelo multicanal, la absorción diferencial correlaciona LST con temperaturas de brillo TOA a través de coeficientes derivados de análisis de regresión. Este método presenta una dependencia angular de LST y LSE (Sobrino and Jiménez-Muñoz, 2005). Además, Taheri et al., (2022) señalan que al tener distintos ángulos de visión se pueden proporcionar diferentes características de un mismo objeto, por lo cual su enfoque no es adecuado en áreas heterogéneas y condiciones atmosféricas inestables. Se puede encontrar una revisión profunda de esta técnica en Sobrino et al., (1996).

### 2.3.1 Fuentes de datos para la obtención de LSE

La precisión de la LST recuperada desde sensores satelitales depende de 2 factores fundamentales: la corrección de efectos atmosféricos y la estimación precisa de la LSE. Una variación de 0,01 unidades en la emisividad produce un sesgo de 0,5 °C (Sobrino et al., 2012). Los algoritmos para efectuar la corrección atmosférica de LST a través de métodos monocanal, multicanal y multiángulo, poseen una dependencia explícita de LSE. Es muy complejo tener mediciones *in situ* de emisividad de manera simultánea con el paso del satélite debido a la heterogeneidad de las cubiertas. Los métodos de recuperación de LSE basados en NDVI son operativos y comúnmente utilizados, ya que son fáciles de aplicar y presentan resultados satisfactorios. Bajo este enfoque, se han desarrollado diferentes metodologías para producir mapas de LSE, entre ellos Van De Griend and Owe, (1993) basados en los resultados de un estudio teórico y experimental, demostraron que luego de una transformación logarítmica, el NDVI se encuentra altamente correlacionado con la emisividad. Soportados en este modelo, diversos académicos han modificado y desarrollado los métodos conocidos como umbral de NDVI (NDVI<sup>THM</sup>), que permiten categorizar las cubiertas superficiales para diferenciar emisividades. Por ejemplo, el modelo de Sobrino and Raissouni, (2000), realiza la estimación de LSE empleando 3 funciones lineales que corresponden a las condiciones en las que un píxel se compone de vegetación total, suelo o mezcla de suelo-vegetación (Tang et al., 2015). Este algoritmo no es siempre confiable por la dificultad del NDVI para discriminar la emisividad del suelo en superficies impermeables (Sobrino et al., 2008). También, Valor and Caselles, (1996) propusieron un modelo ampliamente aceptado por la comunidad científica, que define la emisividad efectiva para una superficie rugosa y heterogénea a partir de las emisividades de sus componentes y de una estimación de la fracción de cobertura vegetal ( $F_{COVER}$ ). La  $F_{COVER}$  es una variable biofísica empleada para describir la calidad y composición de la vegetación, y se representa como el porcentaje de la superficie del suelo cubierta por vegetación (Yu and Guo, 2021). Adicionalmente, para emplear estos modelos se debe contar con las emisividades del suelo desnudo y vegetación. Los algoritmos basados en índices de vegetación estiman la emisividad con errores entre 1 y 2% (Caselles et al., 2012).

También se tienen a disposición diferentes productos consistentes y calibrados que, proporcionan mapas de emisividad global de forma directa a partir de múltiples misiones y sensores satelitales como los productos MODIS (MOD21) y ASTER *Global Emissivity Dataset* (ASTER-GED) de EOS-1 (Terra). El producto MOD21 emplea el algoritmo de separación temperatura emisividad (TES) para recuperar LST y LSE desde datos ASTER (Gillespie et al., 1998). Este aplica simulaciones de transferencia radiativa en la corrección de efectos atmosféricos, y para la obtención de LSE se basa en la variabilidad de los datos de radiancia superficial. Los resultados de validación reportan niveles constantes de 1 K (Hulley and Nickeson, 2020). Así mismo, se tienen los productos ASTER-GED que en su versión 3 suministra emisividad promedio entre los años 2000-2008 con resolución espacial de ~100 m. Dado que sus datos son estáticos, se ha desarrollado el producto mensual ASTER GED versión 4 para obtener valores de LSE sobre coberturas heterogéneas sujetas a variabilidad como prácticas agrícolas con una ventana de tiempo entre 2000-2015, empleando el índice de vegetación reticulado mensual MODIS (MOD13C2) (Hulley et al., 2015).

El entorno térmico urbano es con frecuencia de naturaleza compleja y depende de la estructura heterogénea de la superficie terrestre. La estimación de valores LSE provenientes de mediciones de campo con radiómetros, también ha sido empleada como una fuente importante para su obtención y validación (Pérez-Planells et al., 2021). Sin embargo, la emisividad de las cubiertas vegetales se hace compleja por su misma estructura natural. Otro enfoque empleado en la obtención de valores de emisividad, es el basado en modelos de clasificación de coberturas como el producto *Finer-Resolution Observation and Monitoring Global Land Cover* (FROM-GLC), que combinado con librerías de emisividad espectral produce mapas de LSE con resultados satisfactorios, siempre que las cubiertas se clasifiquen de manera precisa (Du et al., 2015), (Ren et al., 2017). Este modelo es conocido como *Classification-Based Emissivity Method* (CBEM).

## 2.4 Modelación de tendencias y contribución de factores asociados a LST

La modelación de sistemas dinámicos como LST, no es una tarea fácil por el acople existente entre los factores influyentes que controlan sus cambios. La determinación de patrones locales y factores predictores que transforman el régimen térmico, son significativamente relevantes para que los planificadores territoriales definan políticas de adaptación ante los efectos adversos de SUHI. Bajo este enfoque, se ha estudiado la aplicación de procedimientos de modelado que permiten evaluar la contribución y tendencia de varios factores al fenómeno. Para este propósito, una combinación de análisis de componentes principales (PCA) y regresión lineal múltiple (MLR) permiten comprender las variaciones térmicas, prestando atención a la estructura de la serie temporal de las variables estudiadas.

El PCA es una técnica estadística que utiliza una transformación ortogonal para convertir un conjunto de observaciones variables correlacionadas, en un conjunto de valores de variables linealmente no correlacionadas. La transformación se logra calculando la matriz de varianzas/covarianzas de los datos originales y descomponiéndola en sus coeficientes. Esos coeficientes son cantidades estadísticas conocidos como autovectores (*eigenvectors*) o componentes principales (PC) (Abate et al., 2020), (Song et al., 2021). Los PC están dispuestos en orden de varianza decreciente por lo que el más informativo es el primero y el menos informativo el último (Gaitani et al., 2010). El porcentaje de la imagen original que queda explicado en cada uno de los PC se llama autovalor (*eigenvalue*). El PC1 de las bandas apiladas produce una imagen que muestra los píxeles con la mayor variación, con valores altamente positivos o negativos. Los píxeles con poca o ninguna variación tendrán un valor de puntuación cercano a cero (Gaitani et al., 2017). Dada la naturaleza de las transformaciones lineales que concentran la información en términos su variabilidad, esta técnica ha sido ampliamente empleada para obtener tendencias y caracterizar patrones espaciotemporales de diversos factores biofísicos (Sangines, 2013), (Parmentier, 2014), (Firozjaei et al., 2019), (Lemus-Canovas et al., 2020).

La contribución de diversos factores ambientales sobre LST ha sido explorada por distintos métodos que incluyen, regresión ponderada geográficamente (GWR) (Zhi et al., 2020), regresión por mínimos cuadrados ordinarios (OLS) (M. Liu et al., 2021), métricas de geodetección (W. Liu et al., 2021) y regresión lineal múltiple *stepwise* (MLR).

MLR es un modelo estadístico que ajusta a una ecuación lineal la relación entre variables explicativas y la variable de respuesta. Su función de regresión se basa en la minimización de la suma de los residuos al cuadrado y está definida por la Ecuación 8. La inclusión o eliminación de candidatos predictores dependerá de su significancia dentro del modelo, definida por una prueba de hipótesis sobre el coeficiente asociado a la variable (Wilks, 2019).

$$Y = \beta_0 + \sum_{i=1}^n \beta_i \cdot X_i + \varepsilon \quad (8)$$

En esta ecuación,  $n$  es el número de variables independientes,  $\beta_0$  es el término independiente,  $\beta_i$  es el coeficiente parcial de regresión para  $X_i$ ,  $\varepsilon$  es el error de observación asociado a variables no controladas.

MLR *stepwise* como herramienta predictiva ha sido ampliamente utilizada para analizar la relación entre diversos factores ambientales y la LST, porque, evalúa el efecto de cada predictor en presencia de todas las variables. En cada paso (*step*) el modelo ingresa una variable adicional y evalúa si esta adición mejora significativamente su calidad. Si se halla significancia en la variable, esta es agregada al modelo y se repite el proceso para las demás variables analizadas (Zeng et al., 2021), (Onáčillová et al., 2022). El coeficiente de determinación  $R^2$  señala la porción de varianza explicada en la variable dependiente por las variables independientes, es decir, refleja la medida de la bondad del ajuste. Sin embargo, cuando se emplea *stepwise* para ajustar la ecuación de regresión, se puede presentar alta correlación entre las variables explicativas, esto se conoce como multicolinealidad y ocasiona distorsiones al modelo (Zeng et al., 2021). Además de la multicolinealidad, MLR tiene supuestos de autocorrelación y normalidad residual, que resultan mandatorios de revisión para validar la fiabilidad de la ecuación. Así mismo, la presencia de datos atípicos puede perturbar e invalidar el modelo porque transmiten las características de los datos

extremos (Zhao et al., 2020). Los valores atípicos se pueden detectar calculando el rango intercuartílico (IQR). IQR es la diferencia entre el tercer cuartil ( $Q_3$ , percentil 75) y el primer cuartil ( $Q_1$ , percentil 25). Los valores atípicos se hallarán por fuera de los límites definidos en la Ecuación 9.

$$\bar{x}_i < Q_1 - 1,5 \cdot IQR \quad \text{ó} \quad \bar{x}_i > Q_3 + 1,5 \cdot IQR \quad (9)$$

## 2.5 Algoritmos de aprendizaje automático (ML)

La geomática ha realizado avances significativos en el desarrollo de metodologías para comprender la dinámica socioeconómica, ambiental y de los ecosistemas. Las misiones de observación de la Tierra proporcionan una cantidad de información geográfica sin precedentes que requiere de algoritmos eficientes para procesarla debido a la complejidad y variabilidad de los fenómenos observados. Los sistemas de aprendizaje automático (ML) son enfoques informáticos que tienen la capacidad de aprender y mejorar de manera automática a partir de un conocimiento previo. Su eficiencia depende de la naturaleza y características de los datos y del rendimiento del algoritmo empleado. La aplicación de métodos de ML sobre datos recuperados desde técnicas de teledetección ha obtenido resultados sólidos en la extracción de características estructurales subyacentes de los datos, incluso cuando se dispone de una poca cantidad de ellos. Los algoritmos de ML como modelos de regresión y árboles de decisión han demostrado importantes resultados en la clasificación de imágenes satelitales, y la caracterización de procesos dinámicos altamente variables como la temperatura en áreas urbanizadas. Sin embargo, es necesario implementar metodologías que permitan mejorar la precisión de los modelos de aprendizaje automático de propósito general, con un enfoque que permita mayor eficiencia en el reconocimiento de patrones y la segmentación de imágenes térmicas frente a la mitigación del impacto de las actividades humanas sobre el medio. En este contexto algoritmos como, *Artificial Neural Networks* (ANN), *Support Vector Machine* (SVM), y *Random Forest* (RF) han recibido mucha atención por su capacidad de manejo de datos de alta dimensionalidad resolviendo problemas complejos para lograr la separación de clases.

Un trabajo reciente presentado por [Barca et al., \(2020\)](#) contrasta los algoritmos referidos con un modelo de enfoque Bayesiano, *Naïve Bayes*, sustentando que este ofrece predicciones de mayor precisión con muestras de entrenamiento limitadas. Además, señala que futuros estudios podrían considerar el uso de la técnica PCA para reducir el espacio de datos espectrales y, en consecuencia, la carga computacional. Bajo este enfoque, esta investigación emplea 2 algoritmos de aprendizaje automático, *Support Vector Machine* (SVM) y *Weighted Naïve Bayes* (WNB) con el fin de producir mapas SUHI y evaluar su rendimiento, a través de agrupación de píxeles relativamente homogéneos.

### **2.5.1 Support Vector Machine (SVM)**

SVM es uno de los algoritmos de aprendizaje automático supervisado de mayor eficiencia en la segmentación de datos lineales y no lineales aplicado a sensores remotos ([Baqa et al., 2022](#)), ([Wei et al., 2022](#)). Al ser una técnica no paramétrica no hace suposiciones sobre la distribución estadística de los datos. El modelo se basa en la teoría del aprendizaje estadístico y la función *kernel*. Su objetivo es realizar la búsqueda iterada de aquel hiperplano, que deje el mayor margen posible libre de datos entre clases de entrenamiento. El término ‘hiperplano’ actúa como una regla de decisión lineal que emplea una función de mapeo derivada de las muestras de entrenamiento, y que busca minimizar las clasificaciones erróneas ([De Luca et al., 2019](#)). Los valores más cercanos al margen de clasificación son los llamados vectores de soporte. Luego, el modelo evalúa la estimación del hiperplano, haciendo predicciones con el conjunto de datos de prueba. Si los resultados de la predicción son incorrectos, se hace una nueva selección de los vectores de soporte y se ajusta un nuevo hiperplano.

En la práctica, los grupos de diferentes clases se superponen a otra clase creando dificultad en la separabilidad lineal. Cuando esto sucede se busca simplificar el problema de optimización a través de una función *kernel*, para realizar proyecciones en espacios de mayor dimensionalidad, donde la separación de las clases sea lineal ([Mountrakis et al., 2011](#)).

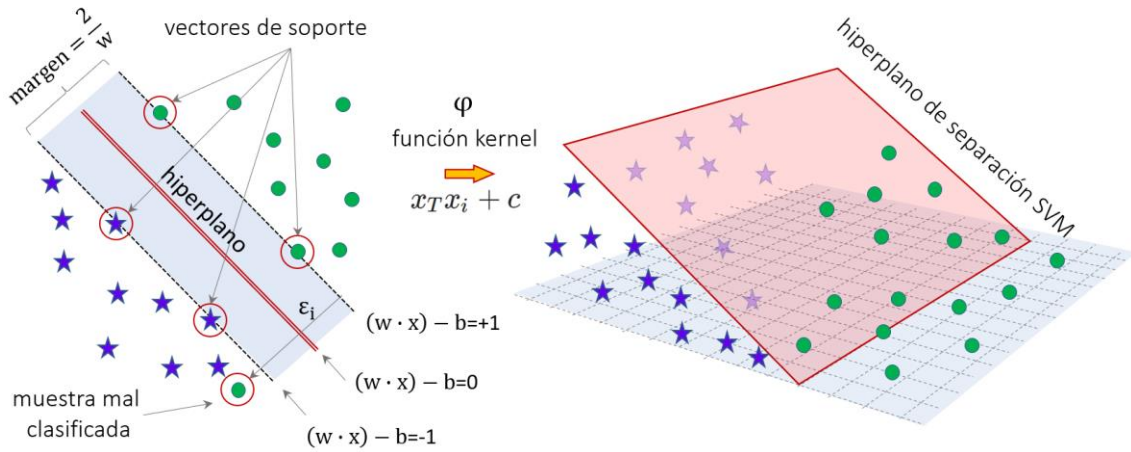


Figura 7. Modelo de clasificación basado en SVM

SVM define el hiperplano asumiendo que el conjunto de entrenamiento tiene  $n$  muestras, es decir,  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ , donde,  $x_i$  es un vector de una determinada clase,  $y_i$  es la etiqueta de clase.  $x_i \in \mathbb{R}$ ,  $y_i \in \{-1, +1\}$ . El problema de clasificación binaria establecido en la Figura 7, se puede separar usando una función de decisión lineal (Okwuashi and Ndehedehe, 2020):

$$f(x) = w \cdot x + b \quad (10)$$

En esta ecuación  $w$  es un vector que determina la orientación del hiperplano requerido para la separación, y  $b$  es el sesgo. El hiperplano óptimo necesario para separar los 2 objetos está dado por la Ecuación 11:

$$y_i[(w \cdot x) + b] \geq 1 \quad (11)$$

Para generalizar el proceso de entrenamiento, SVM involucra la optimización de la siguiente expresión:

$$\varphi(w, \varepsilon) = \frac{1}{2} w^2 + C \sum_{i=1}^n \varepsilon_i \quad (12)$$

En la Ecuación 12 se deben cumplir las restricciones,  $y_i[(w \cdot x) + b] \geq 1 - \varepsilon_i$ ,  $\varepsilon_i > 0$ ,  $\forall_i = 1, 2, \dots, n$ ; donde  $w$  es el vector normal al hiperplano,  $\varepsilon_i > 0$  es la variable de holgura que permite la separación imperfecta de clases,  $C$  es un factor de

penalización para controlar el equilibrio entre errores de entrenamiento y márgenes rígidos forzados, fluctúa entre 0 y 1,  $\varphi$  es la función de transformación que mapea patrones linealmente no separables en un espacio de mayor dimensión (M. Wang et al., 2017). Esta transformación incluye los modelos, lineal, función de base radial, y polinomial.

## 2.5.2 Weighted Naïve Bayes (WNB)

El clasificador *Naïve Bayes* es un algoritmo ampliamente empleado por su simplicidad y eficiencia en el reconocimiento de patrones. *Naïve Bayes* es una técnica de clasificación basada en el Teorema de Bayes. El modelo supone que los valores de las variables en una clase, no están relacionados con los valores de las variables de otras clases (Musial and Bojanowski, 2022); esto se conoce como independencia condicional de clase y por ello se considera ‘ingenuo’.

La probabilidad de ocurrencia de un evento (*a posteriori*) se da en función de las probabilidades condicionales y las probabilidades *a priori* de otros eventos. Estas se obtienen del conocimiento previo adquirido de las muestras de entrenamiento, luego, las distribuciones de probabilidades *a posteriori* se obtienen con la fórmula Bayesiana de la Ecuación 13. Finalmente, el valor de probabilidad *a posteriori* más alto define la clasificación de la muestra analizada (Shu et al., 2021). Al usar *Naïve Bayes*, es necesario calcular el producto de múltiples probabilidades para obtener la probabilidad de clasificación  $\prod_{i=1}^n P(X_i|C_k)$ . El clasificador calcula la probabilidad *a posteriori* de que un vector  $X$  pertenezca a la clase  $k$ ,  $P(C_k|X)$  como:

$$P(C_k|X) = \frac{P(X|C_k) \cdot P(C_k)}{P(X)} \quad (13)$$

$P(X|C_k)$  es la probabilidad condicional de observar  $X$  desde  $C_k$  (función de densidad de probabilidad (PDF)),  $P(C_k)$  es la probabilidad *a priori* de la clase  $k$ ,  $P(X)$  es la misma probabilidad de observar  $X$  en cada clase.

Se asume que cada conjunto de datos de entrada tiene  $n$  atributos característicos  $X = \{X_1, X_2, \dots, X_n\}$  y  $m$  clases de decisión  $C = \{C_1, C_2, \dots, C_m\}$ , dada

la premisa de la independencia entre atributos, que  $P(X)$  no depende de  $C_k$ , y que cada entrada  $i$ -ésima,  $X_i$ , ya se ha presentado, entonces  $P(X)$  puede ignorarse en la [Ecuación 13](#). Por lo tanto, se puede reescribir así ([Barros et al., 2022](#)):

$$k(x) = \arg \max P(C_k) \prod_{i=1}^n P(X_i|C_k) \quad (14)$$

El clasificador supone que cada variable es independiente y contribuye de manera equitativa a la probabilidad de que una muestra pertenezca a una clase específica ([Misra and Li, 2020](#)). Sin embargo, en las aplicaciones del mundo real, estos supuestos son difíciles de satisfacer ([Jiang et al., 2019](#)). En el conjunto de atributos algunos tienen mayor importancia que otros, por lo que deberían tener mayor influencia en el modelo final que los atributos menos importantes ([Zhang et al., 2021](#)). Ponderar diferentes atributos con los coeficientes adecuados es un forma de debilitar la suposición de que estos son independientes e igualmente importantes ([Shu et al., 2021](#)), por tanto, una observación que se ve afectada por un peso particular ( $w_i$ ) se define dentro una clase específica cuando la probabilidad *a posteriori* alcanza el valor máximo de acuerdo con la siguiente expresión ([Zhang et al., 2020](#)):

$$k(x) = \arg \max P(C_k) \prod_{i=1}^n P(X_i|C_k)^{w_i} \quad (15)$$

Las probabilidades *a priori*  $P(C_k)$  y condicionales  $P(X_i|C_k)$  se determinan a través de un proceso de entrenamiento previo. Entonces, la [Ecuación 15](#) se convierte en:

$$k(x) = \arg \max \hat{P}(C_k) \prod_{i=1}^n \hat{P}(X_i|C_k)^{w_i} \quad (16)$$

En esta ecuación,  $\hat{P}(C_k)$  y  $\hat{P}(X_i|C_k)$  son estimaciones de las funciones de densidad de probabilidad (PDF). Estas se derivan de la frecuencia de sus respectivos

argumentos desde las muestras de entrenamiento. La [Figura 8](#) señala el funcionamiento del NBW.




Figura 8. Modelo de clasificación basado en WNB

“La ciencia es la progresiva aproximación del hombre al mundo real”

Max Planck (1858 – 1947)

# CAPÍTULO 3

## ÁREA DE ESTUDIO Y MATERIALES

**RESUMEN:** *Este capítulo refiere las principales características físicas de la ciudad de Cartago, así como los conjuntos de datos primarios provenientes de sensores remotos utilizados en esta investigación. Estos están compuestos por imágenes satelitales de los productos Landsat-5 TM, Landsat-7 ETM+, Landsat-8 OLI/TIRS, y Sentinel-2 del sensor MSI. Se menciona su disponibilidad para el área de estudio, en términos de cobertura de nubes y algunas características como su resolución espacial y niveles de procesamiento. Finalmente, se describen los termómetros ensamblados y su proceso de calibración, como un sistema de medición independiente para comparar de manera directa los valores de LST recuperados desde Landsat-8 OLI/TIRS.*

### 3.1 Área de estudio

El estudio se centra en la ciudad tropical de Cartago, Colombia (Figura 9). Se ubica sobre la margen derecha del Río Cauca, considerado el segundo río más importante de la nación. Cubre un área de 279 km<sup>2</sup> y una población de 135 mil habitantes. La ciudad es topográficamente plana y se encuentra en un piso térmico de temperatura cálida con precipitación media anual de 1578 mm y temperatura media diaria de 23,8 °C. De acuerdo con reportes oficiales la diferencia máxima anual de temperatura promedio es de 1 °C (Municipio de Cartago Valle del Cauca - Alcaldía de Cartago, 2013). La posición geográfica de su punto central es 4,75°N y 75,9°W y altura de 917 m s. n. m. La ciudad es considerada geográficamente estratégica en el contexto de la región del pacífico colombiano por su conexión entre el aeropuerto internacional de carga Santa Ana y el centro del país a través de la troncal de occidente, que hace parte de la carretera Panamericana.

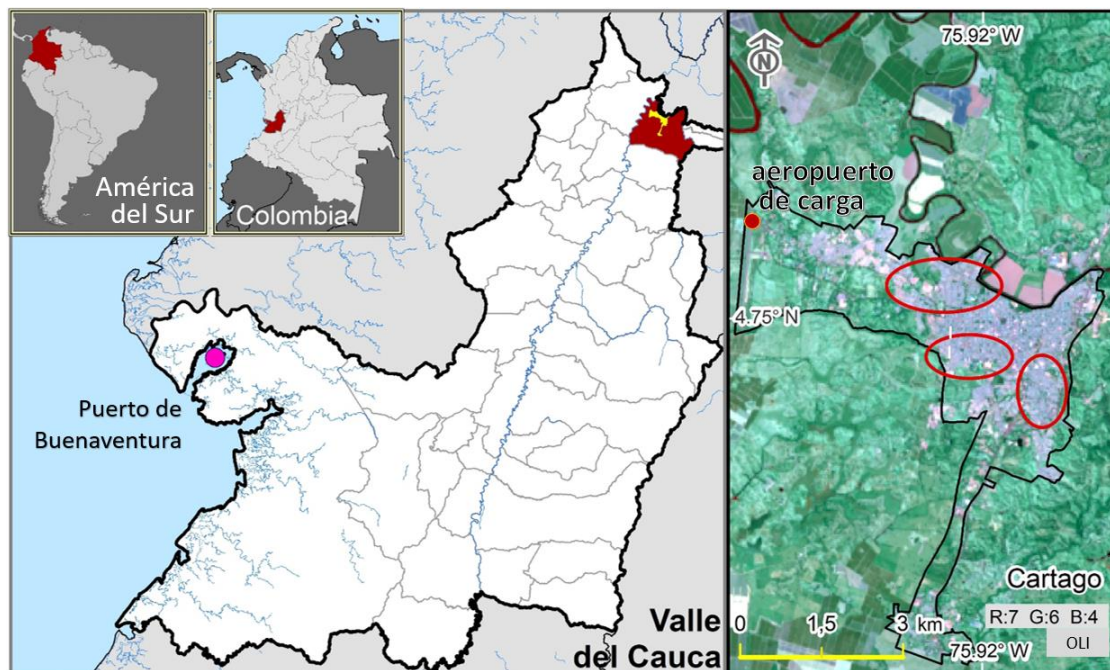


Figura 9. Localización del área de estudio

Su tipología constructiva está compuesta principalmente por edificaciones de arquitectura colonial y republicana, con paredes gruesas y techos altos de barro que proporcionan una buena inercia térmica. Cartago cuenta con una malla vial básica de 180 km y se encuentra en el interior del llamado triángulo de oro

conformado por las ciudades de Cali, Bogotá, y Medellín, los 3 principales centros de consumo del país. Su corredor vial primario opera como núcleo funcional de la subregión del norte y centro del departamento, conectando los principales centros de producción y consumo agrícola desde el noroccidente hasta el suroccidente del país con el puerto marítimo de Buenaventura. Su economía se basa en la manufactura textil, bordados y una intensa actividad agrícola dedicada a cultivos de caña de azúcar y cereales. La dinámica demográfica y el proceso migratorio de la zona rural han hecho que Cartago sufra transformaciones en su estructura urbana, especialmente en las áreas demarcadas por los óvalos de color rojo en la [Figura 9](#). De acuerdo con reportes oficiales la aparición de estas nuevas unidades urbanas denota crecimiento desde el centro hacia el noreste en cercanías al río La Vieja, así como hacia el sureste y suroeste de la ciudad. Haciendo una revisión de los resultados del censo realizado por [DANE Departamento Administrativo Nacional de Estadística, \(2018\)](#) la tasa de crecimiento poblacional urbana en el período 2001-2020 fue de 12,3% mientras que la población rural disminuyó 44%.

## 3.2 Materiales

Los materiales empleados en este estudio comprenden varios elementos, que incluyen información vectorial y ráster de cartografía base para la construcción de mapas temáticos, datos de sensores remotos para obtener variables biofísicas, y termómetros portátiles para realizar mediciones de campo. Los datos vectoriales y el ortomosaico de la zona de estudio se han accedido desde los geoportales de datos abiertos del Instituto Geográfico Agustín Codazzi (IGAC) (<https://geoportal.igac.gov.co/>) y del Departamento Administrativo Nacional de Estadística (DANE) (<https://geoportal.dane.gov.co/>). Las imágenes satelitales son provenientes de las plataformas Landsat y Sentinel-2 con diferentes resoluciones y requisitos de procesamiento. A continuación, se describen las principales características de los datos satelitales empleados y los termómetros portátiles ensamblados.

### 3.2.1 Datos de sensores remotos

Para evaluar los cambios térmicos de la zona de estudio se utilizaron 37 imágenes Landsat provenientes de 3 generaciones de sensores: Landsat-5 TM (L5), Landsat-7 ETM+ (L7), y Landsat-8 OLI/TIRS (L8). Las imágenes de uso libre se obtuvieron del sitio web del Servicio Geológico de los Estados Unidos (USGS) (<https://earthexplorer.usgs.gov/>) que ha corregido distorsiones radiométricas y geométricas mediante puntos de control terrestre y DEM a nivel de calidad 1G antes de la descarga. Cada banda espectral es un fichero separado en formato GeoTIFF y tiene sistema de proyección UTM (18N) asociado al datum WGS84. La descarga incluye un fichero MTL que contiene coeficientes radiométricos, constantes térmicas del sensor, ubicación y hora específica de la escena. L5, L7 y L8 tienen resolución espacial de 30 m para sus bandas VIS y NIR, excepto las TIR que son de 120, 60 y 100 m respectivamente.

Además, se utilizaron 11 imágenes del sensor MSI de Sentinel-2 (S2-MSI) corregidas atmosféricamente a nivel 2A para obtener la variable biofísica  $F_{COVER}$ . S2-MSI posee bandas de diferente resolución espacial; las 3 bandas del visible y del infrarrojo cercano tienen resolución espacial de 10 m. Las 3 bandas Red Edge, 1 banda NIR y 2 bandas SWIR tienen resolución espacial de 20 m. Las otras 3 bandas (aerosol costero, vapor de agua y SWIR-Cirrus) tienen resolución de 60 m. Estos productos de reflectancia se encuentran disponibles en el servidor DataHUB de la Agencia Espacial Europea (ESA) (<https://scihub.copernicus.eu/>).

Las limitaciones impuestas por la cobertura de nubes sobre el conjunto multitemporal de datos es una problemática continua que se presenta en los procesos de observación de la Tierra especialmente en las regiones tropicales (Shrestha et al., 2019). Existen 430 imágenes Landsat disponibles de la zona de estudio (path 009 y row 057), pero, solo se usaron 37 de ellas que cuentan condiciones atmosféricas de cielo despejado o índice de nubosidad  $< 5\%$ . Su distribución temporal se representa en la Figura 10. No obstante, esta es una de las zonas de mayor disponibilidad de imágenes en la región andina colombiana. La metodología expuesta es aplicable a otros sitios que no presenten limitaciones impuestas por la cobertura de nubes sobre la efectividad de las bandas VIS/NIR/TIR. En total se emplearon 48 imágenes distribuidas así, 2 L5, 20 L7, 15 L8 y 11 S2-MSI. En el apéndice A se encuentra el listado de imágenes procesadas

con características específicas como, identificador de la escena, fecha y hora de captura.

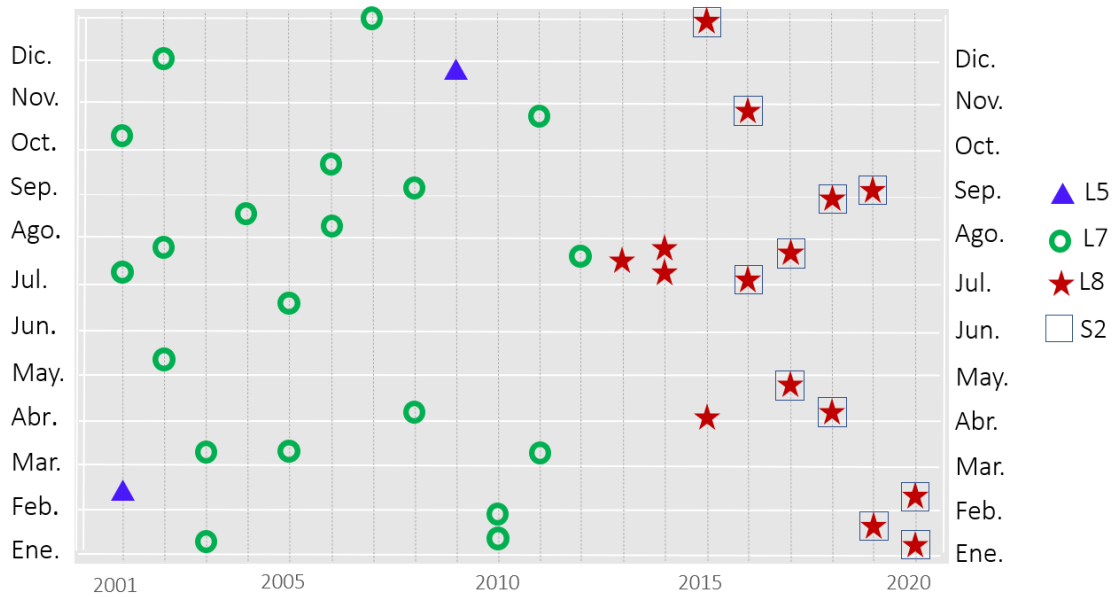


Figura 10. Distribución temporal de las imágenes procesadas

### 3.2.2 Termómetros portátiles ensamblados para contraste de LST

Dado que la LST recuperada de los datos satelitales TIR implica correcciones a las radiancias observadas por el sensor, es necesario evaluar la precisión de su recuperación para suministrar información confiable sobre la calidad del producto (Li et al., 2013a). La comparación de datos *in situ* es considerada la técnica de validación más confiable, sin embargo, debido a la heterogeneidad de las cubiertas asociadas a un mismo pixel, es un modelo exigente que requiere máximo cuidado para determinar mediciones exactas en sitios representativos, que garanticen coincidencia entre la escala espacial de las observaciones *in situ* a nivel de punto y el satélite a nivel de pixel (Guillevic et al., 2018). Sin embargo, los sistemas de medición de temperatura comerciales son costosos.

Para el desarrollo de este proyecto se ensamblaron 30 termómetros portátiles, empleando sensores digitales DS18B20 adaptativos que convierten la señal de

temperatura en señales digitales en serie para el procesamiento computacional con desviación estándar de  $\pm 0,5$  °C, según especificaciones del fabricante disponibles en:

<https://datasheets.maximintegrated.com/en/ds/DS18B20.pdf>.




Figura 11. Prototipo de termómetro empleado para mediciones directas de LST

- (a) Sensor DS18B20. (b) Cubierta metálica de protección. (c) Prototipo ensamblado. (d) Sonda. (e) Termómetros móviles ensamblados. (f) Termómetro patrón.

El sensor DS18B20 se conectó de manera directa a un puerto de entrada/salida digital de un microcontrolador Raspberry Pi. Se emplearon códigos de las bibliotecas ‘OnWire’, ‘RPi.GPIO’, y ‘Adafruit\_CharLCD’ para establecer comunicación con el sensor y leer la temperatura a través de una pantalla LCD. Los códigos se pueden descargar desde la terminal Raspberry Pi que se encuentran disponibles en el repositorio GitHub del autor:

<https://github.com/timofurrer/w1thermsensor>

<https://github.com/dbrgn/RPLCD>

Finalmente, el sensor y el microcontrolador se ensamblaron en una cubierta de lámina metálica resistente que permitió utilizar el dispositivo en condiciones exteriores. El procedimiento detallado para crear la interfaz entre el sensor DS18B20 y el microcontrolador Raspberry Pi, se encuentra en página web de

Circuit Digest: <https://circuitdigest.com/microcontroller-projects/raspberry-pi-ds18b20-temperature-sensor-interfacing>

Los dispositivos fueron calibrados con un termómetro patrón del laboratorio de aguas de la Universidad del Quindío, previo a su uso en campo. Se empleó el método de calibración directa que consiste en registrar las lecturas de los termómetros de prueba y estándar. El termómetro estándar se mantuvo en un medio isotérmico. Se realizaron 5 lecturas para cada prototipo a 20, 30 y 40 °C. Se aplicó la ecuación de regresión de calibración del termómetro patrón para obtener las lecturas corregidas. Finalmente, la lectura corregida del termómetro de prueba se ajustó a una segunda ecuación de regresión contrastando las lecturas del termómetro de prueba con la lectura corregida del termómetro estándar. La corrección ( $t_c$ ) se calcula a partir de la siguiente ecuación:  $t_c = t - t_r$ , donde,  $t_r$  es la lectura del termómetro. Cada termómetro contó con una sonda sensible que permitió contacto directo con la superficie radiante. El objetivo de ensamblar estos termómetros fue tener un sistema de medición independiente para comparar de manera directa los valores de LST recuperados desde Landsat-8 OLI/TIRS. El modelo empleado para el procedimiento de verificación y ajuste de los termómetros se encuentra en el apéndice B.

El costo de cada dispositivo estuvo alrededor de 20 €. Esto permitió ensamblar un número importante de unidades fueron dispuestas en diferentes cubiertas alrededor en el área de estudio, y sirvieron como una herramienta de contraste para los productos de temperatura superficial de L8TIRS B10.

“Equipado con sus cinco sentidos, el hombre explora el universo que lo rodea y a sus aventuras las llama ciencia”

Edwin Powell Hubble (1889 – 1953)

# CAPÍTULO 4

## PROPUESTA METODOLÓGICA

**RESUMEN:** Este capítulo describe los métodos para abordar las preguntas de investigación definidas previamente, centrándose en determinar un modelo efectivo para evaluar los patrones de SUHI a escala local. Para analizar el fenómeno en la ciudad de Cartago se han empleado imágenes satelitales de la plataforma Landsat. La sección 4.1 describe su calibración radiométrica debido a los efectos ocasionados por la atmósfera durante su adquisición. La sección 4.2 refiere de forma detallada los 3 métodos empleados para la obtención de valores de emisividad, como, el CBEM que aplica valores de referencia a través de un mapa de clasificación de coberturas; el ASTER GEDv3; y el modelo  $F_{COVER}$  que integra productos Landsat-8 OLI/TIRS y Sentinel-2 MSI para obtener mapas de LST. La sección 4.3 menciona los detalles relevantes de las 2 campañas de medición directa de valores de temperatura con termómetros portátiles dispuestos en el área de estudio al paso del satélite Landsat-8, para obtener valores de contraste y analizar la calidad de los datos recuperados y calibrados radiométricamente. Luego, la sección 4.4 describe los factores

que se han definido como más relevantes para explicar el comportamiento de LST. Después, la sección 4.5 detalla la manera de emplear la técnica PCA bajo 2 enfoques, por un lado, simplificar el complejo volumen de datos conservando sus variaciones, y por otro, detectar los patrones de LST y de los factores ambientales considerados para clasificarlos con baja pérdida de información. Después, se definieron factores de proximidad de cada píxel a los ríos y al centro urbano. Posteriormente, se empleó la técnica MLR para detectar la dependencia de LST sobre sus predictores, es decir, sobre los factores evaluados. Finalmente, para caracterizar los cambios térmicos en el periodo 2001-2020 se plantea producir 2 mapas de análisis térmico urbano empleando las técnicas de clasificación de aprendizaje automático Support Vector Machine (SVM), y Weighted Naïve Bayes (WNB) teniendo como entradas los factores predictores de LST. El modelo WNB empleado, permite integrar los coeficientes de influencia relativa ( $W_i$ ) derivados del modelo de regresión como peso de cada factor, y se aplicarán métricas convencionales como la precisión global (OA) y el coeficiente Kappa, para determinar la calidad de cada clasificador. Con el producto segmentado de mejor rendimiento, se producirá el mapa de recomendaciones de planificación térmica urbana donde se definirán 4 estados de advertencia térmica: intervenir, monitorear, fortalecer y preservar, enmarcando las isla de calor urbano en las áreas asociadas al primer estado: intervenir.

## 4.1 Preprocesamiento de imágenes

Las imágenes Landsat seleccionadas fueron calibradas radiométricamente para obtener las reflectancias exoatmosféricas normalizadas, usando parámetros del metadato y los modelos dispuestos en [Chander et al., \(2009\)](#) de acuerdo con la misión y sensor específicos. Para minimizar los efectos de dispersión y absorción se realizó la corrección de efectos atmosféricos de las bandas del espectro solar. Esto se llevó a cabo con el módulo *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH). Este algoritmo está disponible en ENVI 5.3 e incorpora el código de transferencia radiativa MODTRAN (*MODerate resolution atmospheric TRANsmision*) que emplea librerías espectrales de alta resolución, para simular la respuesta de aerosoles y moléculas a fin de producir tablas de parámetros atmosféricos ([Larnicol et al., 2018](#)). Los modelos atmosféricos y de aerosoles aplicados a todas las escenas fueron el tropical y urbano, el primero por la ubicación geográfica del área de estudio, y el segundo por tratarse de un

fenómeno analizado en áreas densamente construidas. Tanto el modelo atmosférico como el de aerosoles se emplean para reemplazar los parámetros atmosféricos en tiempo real, mejorando la estabilidad del algoritmo (D. Wang et al., 2019). Finalmente, se hizo un recorte de la escena a través del área de estudio.

## 4.2 Recuperación de la temperatura superficial terrestre (LST)

La LST se recuperó de las imágenes L5TM, L7ETM+ y L8OLI/TIRS. Se aplicó el método monocanal especificado en Barsi et al., (2005). Este modelo emplea la RTE representada en la Ecuación 5 que necesita de la transmisividad ( $\tau$ ), radiancias ascendente ( $L_{\lambda\uparrow}$ ), descendente ( $L_{\lambda\downarrow}$ ) y emisividad espectral ( $\varepsilon$ ) para ser resuelta. Estas variables, excepto la  $\varepsilon$ , se obtuvieron utilizando la calculadora de parámetros de corrección atmosférica de NASA que toma los perfiles atmosféricos de los Centros Nacionales para la Predicción Ambiental (NCEP) como entrada al código de transferencia radiativa MODTRAN (<https://atmcorr.gsfc.nasa.gov/>). Obtener valores precisos de  $\varepsilon$  es complejo por la naturaleza heterogénea de las cubiertas asociada a la composición de sus materiales. Por este motivo, en esta investigación, se han probado 3 métodos de recuperación de emisividad representados en la Figura 12 para obtener de manera precisa la LST desde las imágenes L8OLI/TIRS. El primero, empleando valores de emisividad de referencia basados en un modelo de clasificación (CBEM) (Snyder et al., 1998) (Du et al., 2015), el segundo, a través del producto ASTER GEDv3, y, el tercero, usando la variable biofísica  $F_{COVER}$  propuesto por Valor and Caselles, (1996).

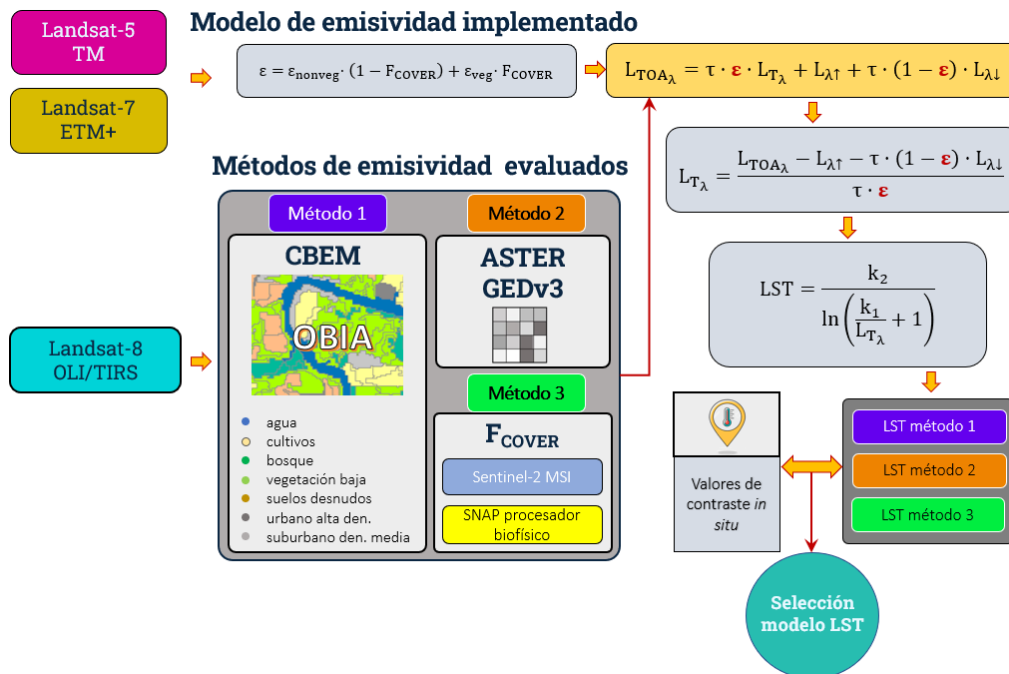


Figura 12. Modelo para la recuperación y evaluación de LST

El primer método, CBEM, utiliza valores de referencia de LSE para aplicarlos a un mapa de clasificación de la cobertura terrestre. Para este fin, se utilizó un modelo clasificación basado en objetos (OBIA) con el software eCognition Developer (<https://geospatial.trimble.com/>), identificando las 7 coberturas expuestas en la Tabla 4. Los modelos OBIA no tratan el píxel de forma aislada, sino en su entorno espacial y espectral agrupando píxeles adyacentes homogéneos para lograr la segmentación empleando sus valores espectrales, tamaño, forma y contexto (Benz et al., 2004), (Akodéwou et al., 2020). Se aplicaron diferentes combinaciones de bandas espectrales para lograr una mejor diferenciación de coberturas y señalar los polígonos de entrenamiento. Dado que no hay referencia de parámetros fijos, el método de ensayo y error ha sido ampliamente usado para detectar la escala de segmentación adecuada (Luo et al., 2018). Como regla general, para fraccionar la imagen en un número finito de regiones se buscó producir objetos en la mayor escala posible, pero, aun así, ser capaz de discernir entre ellos empleando el algoritmo de segmentación-multiresolución. Los coeficientes de escala, forma y compacidad aplicados a la segmentación fueron 80; 0,1 y 0,5 respectivamente. Luego, se aplicó el método de

clasificación *Nearest Neighbor* y se asignaron los valores de emisividad referidos en la [Tabla 4](#) a cada tipo de cobertura.

*Tabla 4. Emisividades de referencia para recuperar LST desde L8/TIRS B10*

Cobertura	Emisividad	Referencia
Cuerpos de agua	0,992	FROM-GLC citado por <a href="#">Du et al., (2015)</a>
Cultivos	0,971	FROM-GLC citado por <a href="#">Du et al., (2015)</a>
Bosque	0,995	FROM-GLC citado por <a href="#">Du et al., (2015)</a>
Vegetación baja	0,986	<a href="#">(Tan et al., 2017)</a>
Suelos desnudos	0,972	<a href="#">(Tan et al., 2017)</a>
Urbana de alta densidad	0,973	FROM-GLC citado por <a href="#">Du et al., (2015)</a>
Suburbano de densidad media	0,971	<a href="#">(Tan et al., 2017)</a>

El segundo método para obtener valores de emisividad, fue a través del producto ASTER GEDv3. Este se deriva con un algoritmo de separación temperatura-emisividad (TES) de datos capturados en condiciones de cielo despejado entre 2000 y 2008. Esta fuente de datos tiene resolución espacial de 100 m y reporta una precisión ~0,01 ([Hulley et al., 2015](#)).

El tercer método empleado en este trabajo para obtener valores de emisividad superficial fue el desarrollado por [Valor and Caselles, \(1996\)](#), que se soporta en la variable biofísica de fracción de cobertura vegetal ( $F_{COVER}$ ), de la siguiente manera:

$$\varepsilon = \varepsilon_v \cdot F_{COVER} + \varepsilon_g \cdot (1 - F_{COVER}) + 4 \cdot \langle d\varepsilon \rangle \cdot F_{COVER} \cdot (1 - F_{COVER}) \quad (17)$$

La variable  $F_{COVER}$  de la [Ecuación 17](#), se obtuvo desde imágenes del sensor MSI de Sentinel-2 (S2-MSI). Para este fin, se usó el procesador biofísico de la plataforma SNAP desarrollada por la Agencia Espacial Europea (ESA) (<https://step.esa.int/main/toolboxes/snap/>). Su algoritmo se basa en modelos de transferencia radiativa asociado a redes neuronales artificiales que caracterizan el dosel a partir de las propiedades de reflectancias de la vegetación ([Weiss and Baret, 2016](#)). La manera de obtener esta variable es distinta a la usada por otros

autores y se presenta como una alternativa novedosa para la modelización térmica con datos Landsat representada en la [Figura 13](#). S2-MSI y Landsat tienen longitudes de onda similares y comparten el mismo sistema coordinado geográfico, lo cual se presenta como una ventaja en la fusión de datos de estas 2 plataformas (Q. Wang et al., 2017).

Dado que las imágenes de L8 y S2-MSI empleadas en este estudio no tienen una temporalidad exacta, se usaron pares con diferencias máximas de 20 días. En zonas tropicales a lo largo del año la dinámica de la vegetación no presenta cambios abruptos, lo que implica que  $F_{COVER}$  no sufre modificaciones drásticas. Los cambios estructurales en esta cobertura se asocian en su mayoría al forzamiento antropogénico.

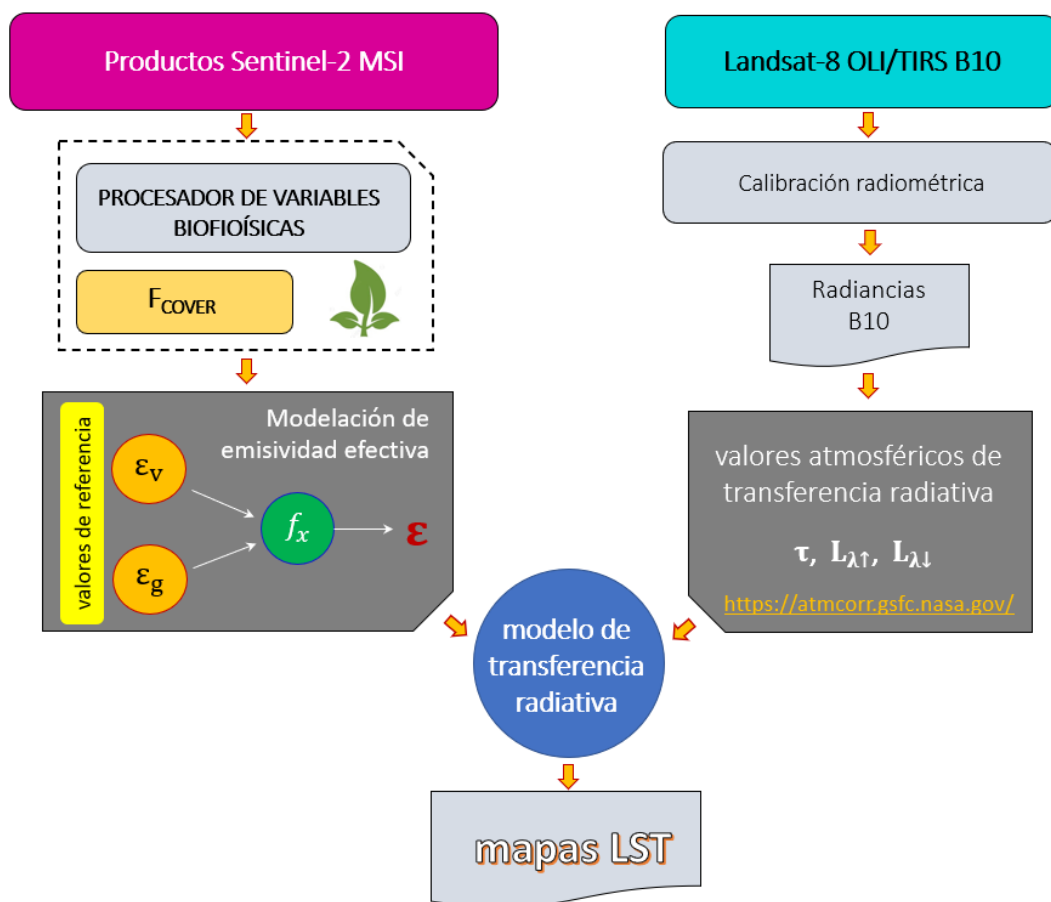


Figura 13. Acople L8 OLI/TIRS B10-S2 MSI para la obtención de mapas LST

Continuando con las variables de la [Ecuación 17](#),  $\varepsilon_v = 0,985$  y  $\varepsilon_g = 0,960$ , corresponden a las emisividades de la vegetación y del suelo desprovisto de ella respectivamente;  $\langle d\varepsilon \rangle$  es la estimación del término de cavidad promedio asociado a la radiancia indirectamente emitida a través de reflexiones internas que ocurren entre vegetación y suelo calculadas con la [Ecuación 18](#).

$$d\varepsilon = (1 - \varepsilon_g) \cdot \varepsilon_v \cdot F \cdot (1 - F_{\text{COVER}}) \quad (18)$$

En esta ecuación, F es el factor de forma de transferencia de energía que depende de la altura H y la separación entre elementos de la superficie S. F se calcula con la [Ecuación 19](#). En árboles menores de 5 m,  $H = (3 \pm 1)$  m y  $S = (3 \pm 1)$  m; y en bosque frondoso  $H = (15 \pm 5)$  m y  $S = (5 \pm 2)$  m ([Caselles et al., 2012](#)).

$$F = \left(1 + \frac{H}{S}\right) - \sqrt{1 + \left(\frac{H}{S}\right)^2} \quad (19)$$

En el caso particular del registro histórico de las imágenes obtenidas desde plataformas L5 y L7 se utilizó el modelo de emisividades de la [Ecuación 20](#), siguiendo el enfoque descrito en [Jiménez-Muñoz et al., \(2009\)](#).

$$\varepsilon = \varepsilon_{\text{nonveg}} \cdot (1 - F_{\text{COVER}}) + \varepsilon_{\text{veg}} \cdot F_{\text{COVER}} \quad (20)$$

En esta ecuación,  $\varepsilon_{\text{nonveg}}$  y  $\varepsilon_{\text{veg}}$  son valores de emisividad de referencia para zonas sin vegetación y con vegetación 0,97 y 0,99 respectivamente ([Jiménez-Muñoz et al., 2009](#)). La  $F_{\text{COVER}}$  se estimó empleando el índice espectral NDVI de acuerdo con [Carlson and Ripley, \(1997\)](#) así:

$$F_{\text{COVER}} = \left[ \frac{\text{NDVI} - \text{NDVI}_{\text{nonveg}}}{\text{NDVI}_{\text{veg}} - \text{NDVI}_{\text{nonveg}}} \right]^2 \quad (21)$$

donde,  $NDVI_{nonveg}$  y  $NDVI_{veg}$  se refieren a los valores de mínima y máxima vegetación extraídos de los puntos de inflexión del histograma de NDVI.

Finalmente, la conversión de  $L_{TOA}$  a LST se logró aplicando las constantes de calibración de cada sensor proporcionadas en los ficheros MTL, y la inversión de la ecuación de Planck en la [Ecuación 7](#).

### **4.3 Contraste de productos LST Landsat-8 OLI/TIRS y mediciones directas**

La medición con datos *in situ* es una forma precisa de evaluar la LST recuperada desde imágenes satelitales ya que proporciona un sistema de medición independiente y de comparación directa, que exige conocer el día y hora de paso del satélite. Debido a su dinámica orbital Landsat-8 OLI/TIRS pasa sobre el mismo punto de la Tierra cada 16 días a la misma hora. Con el objeto de programar las mediciones de campo para su contraste, se consultó el calendario de adquisición de imágenes disponible desde:

[http://landsat.usgs.gov/tools/L8\\_acquisition\\_calendar.php](http://landsat.usgs.gov/tools/L8_acquisition_calendar.php).

Como producto de la calibración de los termómetros portátiles en laboratorio bajo el modelo metrológico descrito en la sección 3.2.2, se comprobó que sus valores de desviación estándar (SD) estuvieron por debajo de los garantizados por el fabricante del sensor ( $\pm 0,5$  °C). Esto sugiere que los termómetros son apropiados para obtener mediciones de LST de forma directa. Se llevaron a cabo 2 campañas de medición simultáneamente con el paso elevado de L8 OLI/TIRS sobre el área de estudio, los días 22/01/2019 y 03/09/2019, a las 10h:20 hora local en condiciones de cielo despejado. El propósito de este procedimiento fue hacer posible el contraste de valores de LST recuperada por satélite con la temperatura medida de forma directa con instrumentos terrestres.



Figura 14. Mediciones de campo con termómetros de portátiles

Los tipos de cobertura de estos sitios de muestreo incluyeron superficies homogéneas de pastizales, bosques, tierras de cultivo, suelos urbanos de media y alta densidad como se presenta en las Figuras 14 y 15. La LST presenta alta variabilidad espacial asociada a la heterogeneidad de sus cubiertas creando desafíos en las comparaciones punto-a-píxel (Yu et al., 2017). Para capturar esta variabilidad se registraron 10 lecturas en un radio de 100 metros. Se empleó este radio de medición para buscar que el valor de la temperatura de contraste se encuentre lo más cerca posible a la resolución espacial del sensor L8 TIRS. La temperatura final se obtuvo como el promedio de todas las lecturas registradas. En cada campaña se registraron valores de temperatura en 30 puntos de muestreo indicados en la Figura 15.

Los valores LST recuperados de las plataformas L5 y L7 no se contrastaron con mediciones directas de campo, por la naturaleza histórica de sus datos. Para referir los errores derivados del procesamiento existen trabajos como el de Li et al., (2004) que reportaron desviaciones de 1,47 y 0,98 °C en la recuperación de LST desde L5 y L7 respectivamente, usando el modelo de emisividades derivado de  $F_{COVER}$  por Carlson and Ripley, (1997), mismo que ha sido empleado en este trabajo.

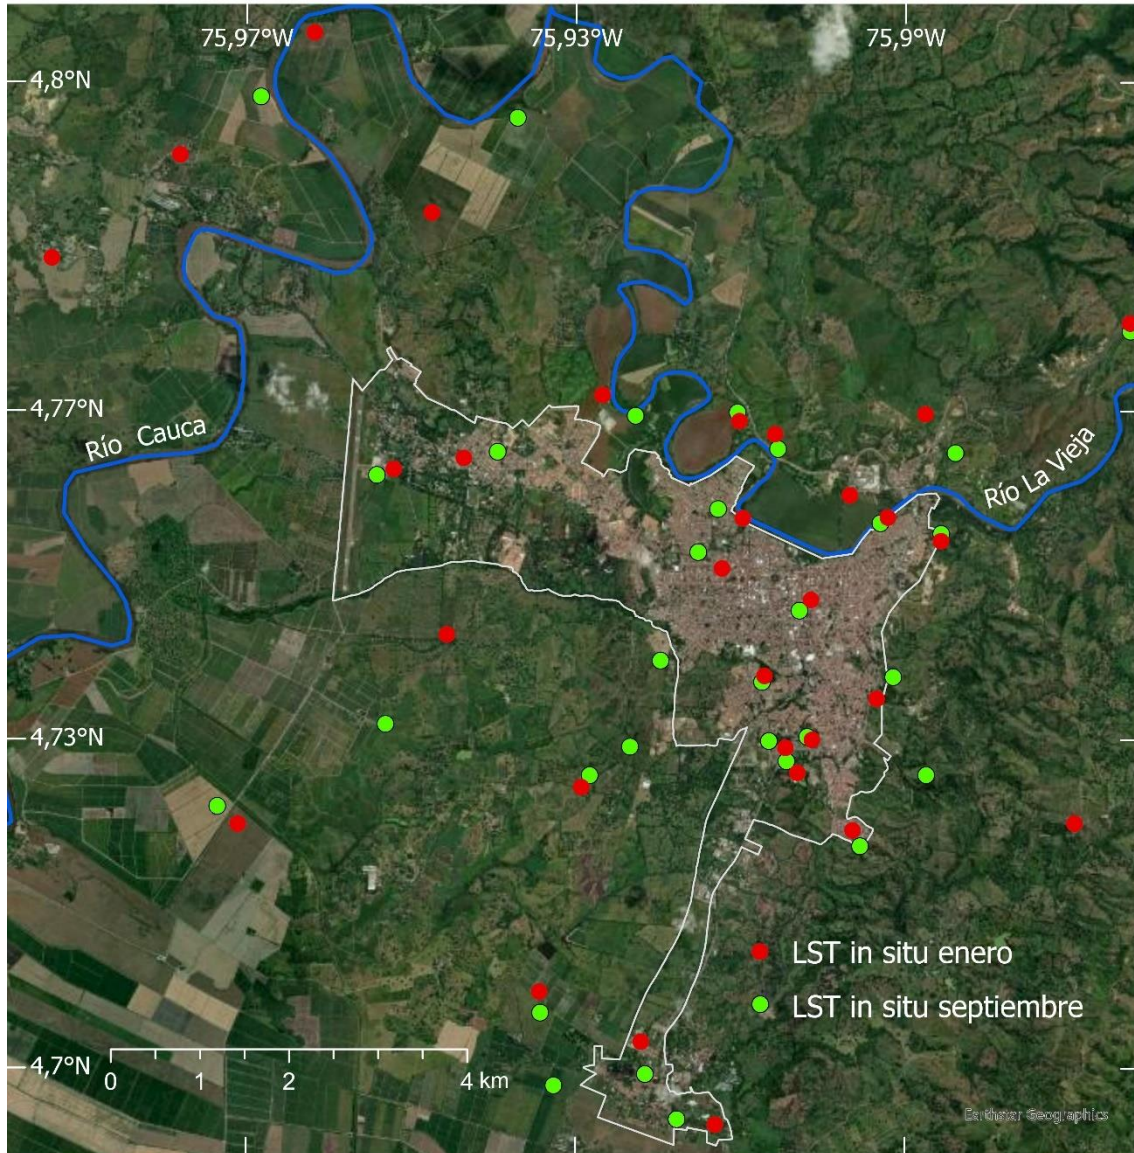


Figura 15. Ubicación de las mediciones LST in situ

## 4.4 Factores candidatos como determinantes de LST

La estructura del sistema urbano exhibe heterogeneidad en la escala espaciotemporal, esto hace que la influencia de los múltiples factores y sus mecanismos de interacción sobre las variaciones de LST sean diversos y complejos. La expansión del suelo urbano, la disminución de cuerpos de agua y cubierta vegetal, y la intensificación de las actividades humanas aceleran la

acumulación de calor antropogénico contribuyendo al aumento significativo de la LST. La cubierta urbana se compone esencialmente de una superficie impermeable. Esto altera la energía superficial y el balance energético aumentando los flujos de calor sensible (Kumar and Shekhar, 2015). La vegetación en el espacio urbano tiene la función notable de dividir la SUHI y disminuir su efecto (Khan et al., 2021). El NDVI es un indicador ampliamente usado para medir la cantidad y el estado de crecimiento de la cubierta vegetal. Este es sensible a la absorción de radiación en la banda roja provocada por la clorofila y a la reflexión de la luz en el NIR. Existe correlación negativa entre LST y NDVI indicando que en ambientes térmicos urbanos la cubierta vegetal puede mitigar la temperatura urbana (Zaitunah et al., 2022). El NDBI ha sido empleado como un indicador de la superficie impermeable urbana dado que favorece el aumento de intercambio de calor sensible, correlacionando positivamente frente a LST (Aslan and Koc-San, 2021), (Zhao et al., 2022). Los cuerpos de agua en áreas urbanas contribuyen a crear zonas de enfriamiento de aire y la disminución de LST pues modifican el intercambio energético entre Tierra y atmósfera, aumentando la humedad a través de la evapotranspiración (Febrita et al., 2021). El NDWI es un índice espectral sensible al contenido de agua en la vegetación y la superficie terrestre, ha sido ampliamente documentado en la literatura con correlación negativa frente a LST (Ahmed et al., 2013), (Khan et al., 2021). Los valores de NDBI, NDVI y NDWI pueden variar de -1 a +1. Los extremos positivos indican áreas densamente urbanizadas, vegetación densa, y masas de agua respectivamente, mientras que otros tipos de cobertura terrestre están representados por valores negativos. Los índices anteriormente mencionados se obtienen de la combinación de bandas espectrales y han sido examinados en este estudio. Su formulación se encuentra en la [Tabla 5](#).

La transformada *Tasseled Cap* (TC) aplica combinaciones lineales a las bandas de las imágenes originales para obtener un significado físico empleando de las características de la superficie: brillo (TCB), verdor (TCG) y humedad (TCW), que pueden asociarse con propiedades biofísicas de la superficie estudiada (Zanchetta et al., 2016). TCB responde a las propiedades físicas que influyen la reflectancia total; TCG a las diferentes densidades de cobertura vegetal; y TCW a la humedad retenida por la vegetación o el suelo (Lamqadem et al., 2018). TC requiere de un conjunto de coeficientes que ponderan las bandas de la imagen

multiespectral de acuerdo con el sensor. Las [Tablas 6, 7, y 8](#) indican los coeficientes de transformación empleados por los diferentes sensores de las plataformas Landsat aplicados en este estudio. Dada la aparente cercanía de la transformada TC con los índices espectrales referidos en el párrafo anterior, resulta interesante compararlos, pues es posible que al emplear las 3 dimensiones TC de manera independiente en el dominio óptico, se logre un análisis más amplio de la superficie dado que la transformada TC explica más del 90% de la variación espectral en escenas individuales ([Bektas Balcik and Ergene, 2016](#)), ([Hu et al., 2020](#)).

Los ríos y lagos tienen alta significancia para el clima urbano, absorben la radiación solar y transforman los flujos de calor sensible a latente proporcionando un efecto de enfriamiento en las áreas circundantes por evaporación ([Gupta et al., 2019](#)), ([Asadi et al., 2020](#)). Los aumentos en la densidad urbana generalmente se asocian con el cambio de las propiedades de la superficie debido a la disminución de los espacios verdes y al aumento de las áreas edificadas ([Wang et al., 2021](#)). Además, la población se agrupa en las zonas centrales de la ciudad por motivos laborales o comerciales incrementando el calor antropogénico. Esto pone de manifiesto la importancia del análisis de proximidad, pues se percibe una relación de cercanía entre ciertas características naturales o artificiales del paisaje y la intensidad térmica. En esta investigación, se emplearon datos vectoriales de los ríos Cauca, La Vieja, y manzanas urbanas, para extraer los factores de proximidad a los cuerpos de agua (PW) y al centro de la ciudad (PUC). Los mapas de estos factores se produjeron con el algoritmo de distancia euclidiana de ArcGIS Pro (<https://esri.com/>).

Finalmente, para este proyecto se seleccionaron 8 factores ambientales señalados en la [Tabla 5](#) como candidatos determinantes de LST, con base en los resultados de estudios previos asociados a las alteraciones del ambiente térmico urbano ([Li and Zhou, 2019](#)), ([Marković et al., 2021](#)), ([Q. Wang et al., 2022](#)). En la caracterización del fenómeno SUHI, la densidad poblacional se considera como un factor socioambiental importante, ya que se asocia con una mayor cantidad de superficies impermeables y, por tanto, mayor almacenamiento de energía calórica. Sin embargo, la información de densidad poblacional no se encontró disponible para los fines del estudio. En su defecto el NDBI presenta alta

correspondencia con la densidad de población. Además, modificar el número de habitantes es una tarea compleja y de largo plazo, lo que significa que no se puede abordar mediante intervenciones específicas de mitigación en el corto o mediano plazo.

Tabla 5. Factores candidatos examinados como posibles descriptores de LST

Acrónimo	Descripción	Formulación del factor	Referencia
NDBI	Índice de construcción	$NDBI = \frac{\rho_{SWIR} - \rho_{NIR}}{\rho_{SWIR} + \rho_{NIR}}$	(Zha et al., 2003)
NDVI	Índice de vegetación	$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}}$	(Tucker, 1979)
NDWI	Índice de agua	$NDWI = \frac{\rho_{Green} - \rho_{NIR}}{\rho_{Green} + \rho_{NIR}}$	(Gao, 1996)
TCB	TC- índice de brillo	$TCB = c_{Blue} \cdot \rho_{Blue} + c_{Green} \cdot \rho_{Green} + c_{Red} \cdot \rho_{Red} + c_{NIR} \cdot \rho_{NIR} + c_{SWIR1} \cdot \rho_{SWIR1} + c_{SWIR2} \cdot \rho_{SWIR2}$	(Crist, 1985), (Huang et al., 2002), (Baig et al., 2014).
TCG	TC- índice de verdor	$TCG = c_{Blue} \cdot \rho_{Blue} + c_{Green} \cdot \rho_{Green} + c_{Red} \cdot \rho_{Red} + c_{NIR} \cdot \rho_{NIR} + c_{SWIR1} \cdot \rho_{SWIR1} + c_{SWIR2} \cdot \rho_{SWIR2}$	(Crist, 1985), (Huang et al., 2002), (Baig et al., 2014).
TCW	TC- índice de humedad	$TCW = c_{Blue} \cdot \rho_{Blue} + c_{Green} \cdot \rho_{Green} + c_{Red} \cdot \rho_{Red} + c_{NIR} \cdot \rho_{NIR} + c_{SWIR1} \cdot \rho_{SWIR1} + c_{SWIR2} \cdot \rho_{SWIR2}$	(Crist, 1985), (Huang et al., 2002), (Baig et al., 2014).
PW	Proximidad a los ríos	$PW = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$	(Peuquet, 1992)
PUC	Proximidad al centro de la ciudad	$PUC = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$	(Peuquet, 1992)

Tabla 6. Coeficientes de las funciones Tasseled Cap para Landsat 5 TM

Acrónimo	B1 Blue	B2 Green	B3 Red	B4 NIR	B5 SWIR 1	B7 SWIR 2
TCB	0,2043	0,4158	0,5524	0,5741	0,3124	0,2303
TCG	-0,1603	-0,2819	-0,4934	0,7940	-0,0002	-0,1446
TCW	0,0315	0,2021	0,3102	0,1594	-0,6806	-0,6109

Tabla 7. Coeficientes de las funciones Tasseled Cap para Landsat 7 ETM+

Acrónimo	B1 Blue	B2 Green	B3 Red	B4 NIR	B5 SWIR 1	B7 SWIR 2
TCB	0,3561	0,3972	0,3904	0,6966	0,2286	0,1596
TCG	-0,3344	-0,3544	-0,4556	0,6966	-0,0242	-0,2630
TCW	0,2626	0,2141	0,0926	0,0656	-0,7629	-0,5388

Tabla 8. Coeficientes de las funciones Tasseled Cap para Landsat 8 OLI

Acrónimo	B2 Blue	B3 Green	B4 Red	B5 NIR	B6 SWIR 1	B7 SWIR 2
TCB	0,3029	0,2786	0,4733	0,5599	0,5080	0,1872
TCG	-0,2941	-0,2430	-0,5424	0,7276	0,0713	-0,1608
TCW	0,1511	0,1973	0,3283	0,3407	-0,7117	-0,4559

## 4.5 Propuesta para la modelización del fenómeno

Modelizar el fenómeno SUHI es evaluar la distribución espacial de LST para detectar patrones organizados de manera similar en el espacio intraurbano y su variabilidad en el tiempo (Cotlier and Jimenez, 2022). Para lograr una modelación efectiva de este fenómeno en el presente trabajo se propone; primero, obtener LST desde imágenes multiespectrales L5, L7, L8, S2-MSI, y seleccionar el método más apropiado para su recuperación aplicando los procedimientos descritos en las secciones 4.1, 4.2, y 4.3. Luego de recuperar los valores de LST se obtendrán los 8 factores ambientales expuestos en la sección 4.4 como candidatos explicativos de LST. Seguidamente, aplicar el análisis de componentes principales (PCA) para obtener los patrones espaciotemporales de los factores evaluados en el periodo 2001-2020, luego, emplear regresión lineal múltiple (MLR) para investigar el impacto y contribución relativa de los factores candidatos explicativos responsables del control de LST. Finalmente, contrastar los resultados de los modelos de clasificación de aprendizaje automático *Support Vector Machine* (SVM), y *Weighted Naïve Bayes* (WNB), y definir a través de las

métricas de calidad cuál de los 2 será empleado para elaborar el *mapa de recomendaciones de planificación térmica urbana*.

Para producir el mapa de variabilidad térmica durante el periodo 2001-2020 se apilaron los valores recuperados de LST en una estructura ráster con 37 bandas. Se le aplicó PCA para obtener la matriz de varianzas/covarianzas y los autovectores a fin de derivar los patrones de LST representados por el PC1. El mismo procedimiento se llevó a cabo para obtener las tendencias espaciotemporales de los factores ambientales estudiados: NDBI, NDVI, NDWI, TCB, TCG, TCW. Los PC1 extraídos del análisis de componentes principales se emplearon como entradas del modelo de regresión lineal, buscando descomponer la tendencia de LST a través de la evaluación de las tendencias de sus predictores candidatos.

Los modelos de regresión son un método eficiente para medir los efectos combinados de múltiples factores impulsores de LST. Para estudiar la descomposición de LST en sus predictores se aplicó el modelo de regresión lineal múltiple (MLR). La MLR se realizó en 2 etapas con el software RStudio (<https://rstudio.com/>). La primera etapa consistió en descomponer la LST en función de sus predictores candidatos empleando el modelo *stepwise*. Para este fin se definió como variable dependiente el PC1 de LST, y como independientes los PC1 de los factores ambientales que incluyeron NDBI, NDVI, NDWI, TCB, TCG, TCW, así como factores de proximidad a los cuerpos de agua (PW), y al centro poblado (PUC).

La **Figura 16** indica el flujo de datos de la modelación espaciotemporal empleada para caracterizar el impacto de los factores ambientales sobre los cambios térmicos y la creación de los mapas segmentados SUHI.

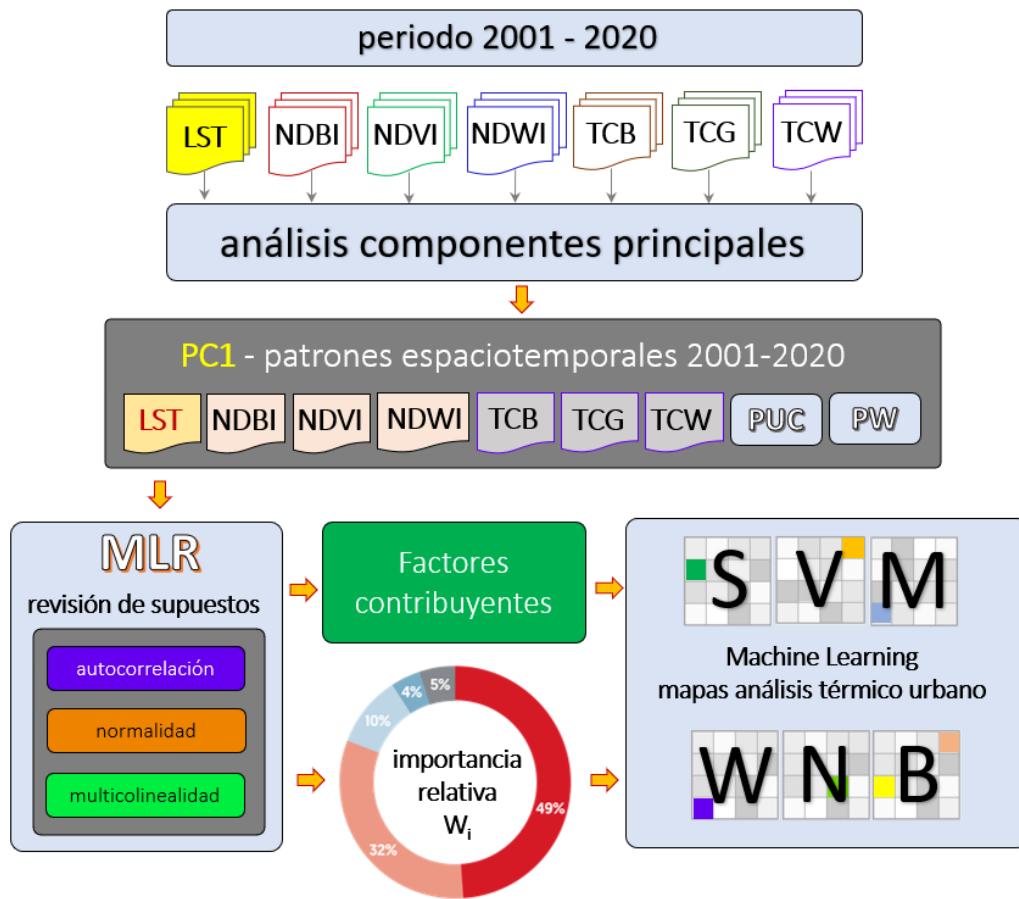


Figura 16. Modelización para propuesta del fenómeno SUHI

En la segunda etapa, se realizó un análisis para definir la influencia relativa de los factores candidatos explicativos de la temperatura. La influencia relativa se refiere a la contribución de cada factor para determinar LST. Para lograrlo, se obtuvieron los coeficientes estandarizados del modelo de regresión ( $\widehat{w}_i$ ). Cuanto mayor sea el valor absoluto de  $\widehat{w}_i$ , mayor será su efecto (Vinod, 2022). Dado que las variables independientes no son representadas bajo la misma unidad de medida, su importancia relativa se examinó estandarizando las variables así,  $\widehat{w}_i = B_i \cdot (S_x/S_y)$ , es decir, expresando el coeficiente de cada variable como la desviación de su media dividida entre la desviación estándar de la variable respuesta. Finalmente, la influencia relativa ( $W_i$ ) de cada variable sobre LST se obtuvo a través de una ponderación en función del valor absoluto de cada factor  $\widehat{w}_i$ . Esto permitió comparar la fuerza del efecto de cada variable independiente sobre la dependiente. Posteriormente, estos coeficientes de influencia

relativa ( $W_i$ ) se emplearon como entradas de uno de los modelos de aprendizaje automático para derivar el mapa de análisis térmico urbano. El código fuente del MLR y de la influencia relativa de las variables se encuentran en el apéndice C.

Con el fin de obtener el *mapa de análisis térmico urbano* se realizó un procedimiento de segmentación usando 2 algoritmos de aprendizaje automático, *Support Vector Machine* (SVM) y *Weighted Naïve Bayes* (WNB). Los datos de entrada a estos algoritmos fueron los factores identificados como contribuyentes significativos de LST. El objetivo fue detectar grupos homogéneos para dividir el espacio en regiones de diferente intensidad térmica categorizando su severidad en 7 niveles expuestos en la [Tabla 9](#).

La intensidad de las SUHI se pueden definir a través de una escala de clasificación LST empleando combinaciones de su valor medio ( $T_a$ ) y desviación estándar (SD) ([Hellings and Rienow, 2021](#)), ([Lu et al., 2022](#)), ([Zhao et al., 2022](#)). Dado que las imágenes utilizadas en el estudio son de diferentes años se aplicó la normalización de LST y los factores ambientales evaluados empleando la [Ecuación 21](#) basada en sus valores mínimo y máximo, lo que permite el reconocimiento de los cambios temporales a través de su distribución estadística ([Firozjaei et al., 2018](#)), ([Weng et al., 2019](#)).

$$\text{factor} = \frac{\text{factor}_i - \text{factor}_{\min}}{\text{factor}_{\max} - \text{factor}_{\min}} \quad (22)$$

En esta ecuación, *factor* es el parámetro ambiental normalizado,  $\text{factor}_i$  representa a la LST y los factores ambientales evaluados de  $i$  pixeles,  $\text{factor}_{\max}$  y  $\text{factor}_{\min}$  son los valores máximo y mínimo de cada factor sobre cada imagen.

Para definir las áreas de entrenamiento sobre el mapa de tendencia LST y aplicar los algoritmos SVM y WNB, se utilizaron muestras extraídas aleatoriamente de los rangos térmicos ajustados de la [Tabla 9](#) descritos por [H. Wang et al., \(2017\)](#) y [Zhao et al., \(2022\)](#). Se muestrearon 10 polígonos por cada rango térmico cubriendo aproximadamente el 0,25% del área de estudio como sugieren [Thanh Noi and Kappas, \(2018\)](#).

Tabla 9. Clasificación de LST en rangos térmicos

Temperatura (clase)	Rango
Extremadamente alta (EHT)	$LST \geq T_a + 2 \cdot SD$
Alta (HT)	$T_a + SD \leq LST < T_a + 2 \cdot SD$
Sub-alta (SHT)	$T_a + SD/2 \leq LST < T_a + SD$
Media (MT)	$T_a - SD/2 \leq LST < T_a + SD/2$
Sub-media (SMT)	$T_a - SD \leq LST < T_a - SD/2$
Baja (LT)	$T_a - 2 \cdot SD \leq LST < T_a - SD$
Sub-baja (SLT)	$LST < T_a - 2 \cdot SD$

El primer modelo de clasificación, SVM, se ejecutó con el software de uso libre Orfeo ToolBox (<https://www.orfeo-toolbox.org/>). Se empleó la función de transformación kernel ( $\varphi$ ) lineal. El factor ‘C’ que controla el equilibrio entre errores de entrenamiento y márgenes rígidos forzados fue 1,0. El parámetro ‘Nu’ que permite la separación imperfecta de clases fue 0,5. Esta combinación de parámetros ha sido evaluada en un trabajo reciente publicado por Vilar et al., (2020) señalando la efectividad del algoritmo. Con este clasificador se obtuvo el primer mapa de análisis térmico urbano SUHI durante el periodo 2001–2020.

El segundo modelo de clasificación WNB se desarrolló implementando la Ecuación 16 a través de la escritura de líneas de código de programación en Matlab (<https://www.mathworks.com>). Los paquetes de software convencionales usados por la comunidad científica para ejecutar procedimientos de clasificación, no presentan alternativas para integrar pesos a las variables del modelo. Bajo la arquitectura de este clasificador representada en la Figura 17 se ingresaron las variables explicativas de LST de forma ponderada para producir el segundo mapa de análisis térmico urbano y contrastarlo con el obtenido desde SVM. El código fuente de programación se encuentra en el apéndice D.

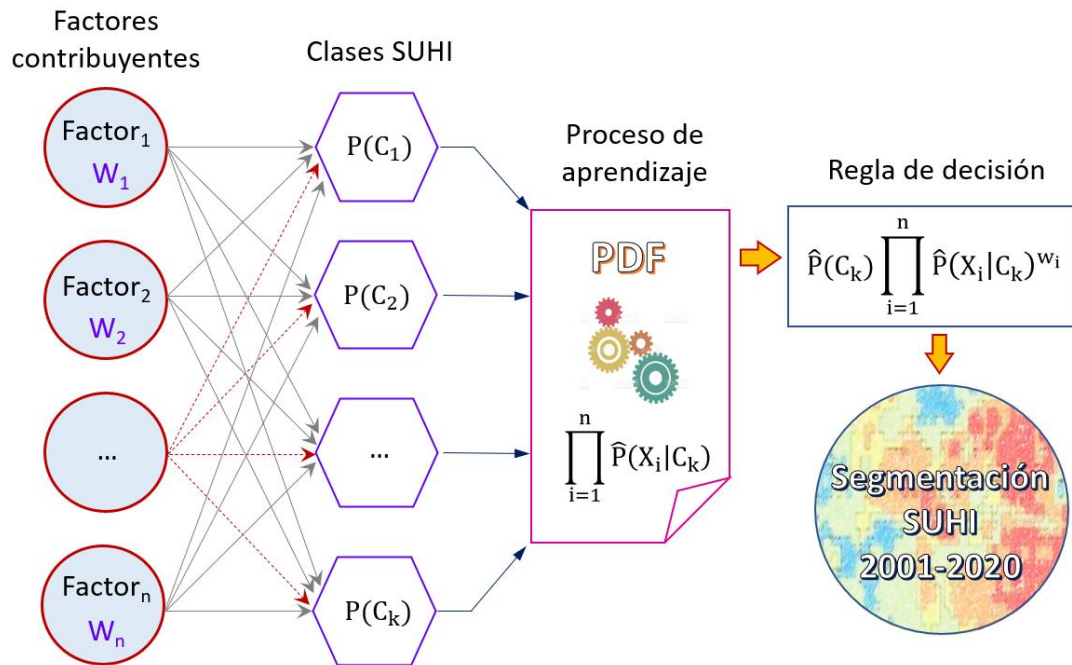


Figura 17. Arquitectura de modelado WNB para generación del producto SUHI

Finalmente, se aplicaron diferentes métricas para medir la calidad de los clasificadores referidas en la [Tabla 10](#). Se emplearon los mismos criterios de las áreas de entrenamiento, pero, se aplicaron en zonas diferentes. Con estos datos se obtuvieron las matrices de confusión para cada clasificador.

La precisión global (OA) se basa en la cantidad de píxeles clasificados correctamente sobre la sumatoria del total de píxeles. El coeficiente Kappa evalúa la concordancia entre conjuntos de datos. La precisión del usuario (UA) refleja la confiabilidad de una determinada categoría identificada como correcta. La precisión del productor (PA) es la relación entre el número total de píxeles clasificados correctamente de una categoría, y el número total de píxeles de referencia para esa clase (X. Li et al., 2022).

Tabla 10. Métricas de evaluación en la precisión de los clasificadores empleados

Índice de evaluación	Fórmula
Precisión global (OA)	$OA = \sum_{i=1}^r x_{ii}$
Coficiente Kappa	$K = \frac{N \cdot \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}$
Precisión del usuario (UA)	$UA = \frac{x_{ii}}{x_{i+}}$
Precisión del productor (PA)	$PA = \frac{x_{ii}}{x_{+i}}$

$x_{ii}$  es el número de muestras clasificadas correctamente,  $x_{i+}$  es el número total de muestras clasificadas en la clase  $i$ ,  $x_{+i}$  es el número total de muestras de la clase  $i$  en las muestras de referencia,  $r$  es el número total de clases,  $N$  es el total de muestras extraídas.

“La inteligencia es la habilidad de adaptarse a los cambios”

Stephen Hawking (1942 – 2018)

## CAPÍTULO 5

# RESULTADOS Y DISCUSIÓN DE LA MODELACIÓN SUHI

**RESUMEN:** *En este capítulo se describen y discuten los resultados de esta investigación después de aplicar la metodología definida en el capítulo 4. Se proporciona un análisis completo de los parámetros involucrados en la LST para la ciudad de Cartago, y un modelo calibrado para la caracterización del fenómeno SUHI en áreas urbanas. Inicia con la sección 5.1 que revela los resultados de los valores recuperados de LST L8/TIRS B10 empleando 3 fuentes de datos de emisividad, contrastados con las mediciones directas a través de los termómetros portátiles. Luego, en la sección 5.2 se analizan los componentes principales (PCA) de la temperatura y las variables ambientales propuestas como sus candidatos explicativos, a través de su máxima varianza representada en el PC1 para detectar las tendencias espaciotemporales. Posteriormente la sección 5.3 se enfoca en la identificación de los factores explicativos de LST a través de un modelo de regresión lineal múltiple (MLR) así como la influencia relativa de cada factor. También se incluye la discusión del análisis de supuestos de la modelación estadística. Subsecuentemente, la sección 5.4 presenta los resultados de la segmentación en unidades térmicas empleando los algoritmos Support Vector Machine (SVM), y Weighted Naïve Bayes (WNB) que*

*permitió integrar la influencia relativa de los factores explicativos de LST. También, se presentan los resultados de las métricas de calidad aplicada a los algoritmos de clasificación empleados. Todo esto permitió elaborar el mapa de recomendaciones de planificación térmica urbana, sobre el cual se identificaron 4 estados: intervenir, monitorear, fortalecer y preservar. Nuestras ciudades se enfrentan a desafíos ambientales ocasionados por los excesos irracionales del uso de la tierra sobre los recursos naturales, que exigen respuestas y medidas de adaptación rápidas. Es imperativo buscar patrones de desarrollo sostenible de la tierra que se adapten a las condiciones de la urbanización existente y minimicen sus impactos térmicos perjudiciales. Bajo este enfoque la sección 5.4 explora perspectivas e implicaciones para la planificación urbana soportadas en los 4 estados de advertencia identificados en el mapa de recomendaciones de planificación térmica urbana.*

## **5.1 Estimación de LST**

Los 30 termómetros ensamblados se emplearon como herramienta de contraste de la LST recuperada de L8/TIRS B10. Los registros de medición directa de temperatura se realizaron en 2 campañas de medición los días 22/01/2019 y 03/09/2019. Las 30 medidas adquiridas durante cada campaña se compararon con los valores recuperados de LST derivados de los 3 modelos de LSE evaluados para caracterizar su sensibilidad. Los diagramas de caja y bigotes de la [Figura 18](#) señalan la variación de las mediciones indicando las diferencias entre los 3 modelos evaluados. El punto de color rojo señala el error medio. La comparativa entre ambas fechas (enero y septiembre) sugiere que el método  $F_{COVER}$  exhibió un comportamiento prácticamente idéntico, mientras se apreciaron resultados disímiles para los otros 2 métodos, ASTER y CBEM.

Los resultados de la campaña de enero sugieren que la amplitud de los errores de LST fue cercana entre los modelos evaluados. El modelo  $F_{COVER}$  capturó mejor la variabilidad espacial de la emisividad con error medio de 1,3 °C. La línea horizontal al interior de la caja correspondiente a la mediana se encuentra por encima de la media, lo que se interpreta como una leve sobreestimación en los valores recuperados de LST. Los modelos ASTER y CBEM presentaron

comportamientos cercanos entre ellos con errores medios de 1,9 y 2,3 °C respectivamente.

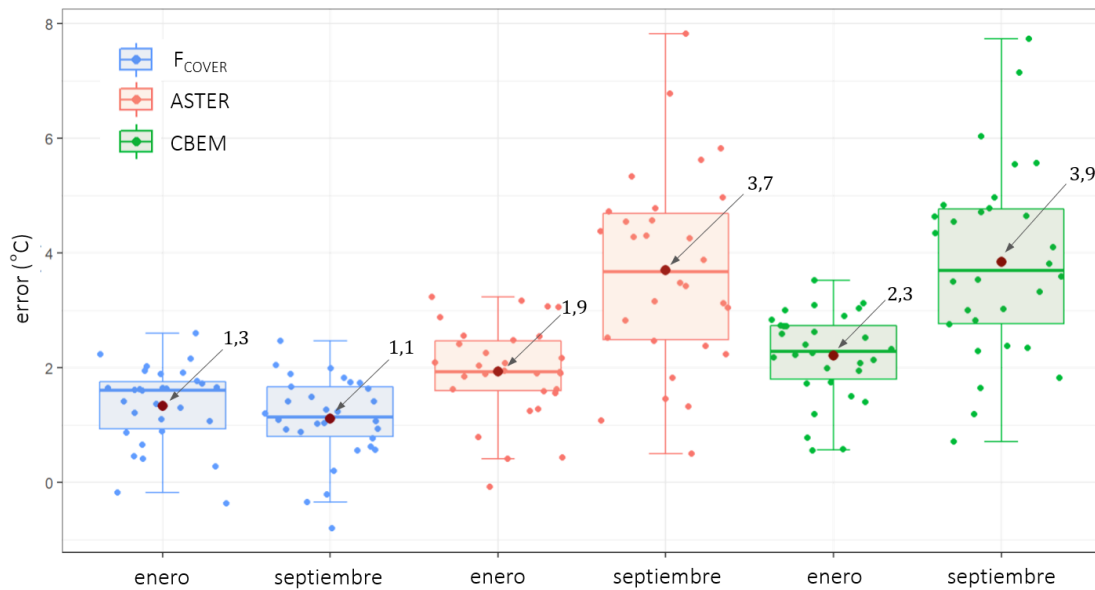


Figura 18. Contraste modelos LSE en la recuperación de LST L8/TIRS B10

Los registros de medición de septiembre nuevamente indicaron que el modelo  $F_{COVER}$  produjo la menor desviación con error medio de 1,1 °C, mostrándose muy notoria frente a ASTER y CBEM que presentaron desviaciones medias de 3,7 y 3,9 °C respectivamente. El modelo original usado en este trabajo que acopla imágenes L8 y S2-MSI a través del procesador biofísico del software SNAP, produjo los menores errores en recuperación de LST convirtiéndole en un interesante modelo híbrido de monitoreo confiable de variables biofísicas. Aunque, los datos de campo restringen el alcance del modelo de validación LST a un número limitado de pixeles, sugieren que los sitios de muestreo presentaron cubiertas suficientemente homogéneas a la escala del pixel, y sirven como evaluación directa de la calidad radiométrica del sensor y la robustez del algoritmo para recuperar LST, como señalan Li et al., (2013a).

Adicionalmente, se hizo el contraste a través de regresión lineal entre las temperaturas registradas en campo y LST derivada de L8 con los 3 modelos de LSE propuestos. La Figura 19 indica la correspondencia de las mediciones, y

señala que el coeficiente de determinación  $R^2 = 0,78$  y  $SD = 0,73$  de  $F_{COVER}$  tuvo correlación positiva alta exhibiéndose como el de mejor ajuste.




Figura 19. Ajuste entre medición directa y LST L8 con diferentes fuentes LSE

Por el contrario, para los otros 2 casos, es decir, emisividades ASTER y CBEM, sus coeficientes de correlación alcanzaron  $R^2 = 0,27$  y  $R^2 = 0,26$  con valores de SD mayores, como se observa en la Figura 19. Las áreas grises representan los límites de confianza del 95%, mientras que las líneas continuas representan las rectas de mejor ajuste entre el LST calculado y las observaciones *in situ*. Este análisis de regresión refuerza los resultados de la comparación anterior, y permite considerar que las emisividades derivadas del modelo  $F_{COVER}$  produjeron un buen ajuste en la recuperación de los valores LST del conjunto de datos de Landsat 8.

Como consecuencia del análisis de sensibilidad de los 3 métodos de estimación de LSE evaluados en este trabajo, se optó por aplicar el método original  $F_{COVER}$  que integró imágenes de S2-MSI a la serie temporal de productos L8/TIRS B10 adquiridos desde 2015. Para los datos recuperados de las bandas térmicas de L5, L7, y L8 anteriores a 2015 la variable  $F_{COVER}$  se obtuvo a partir del índice espectral NDVI, como se refiere en la sección 4.2 siguiendo los modelos descritos en Jiménez-Muñoz et al., (2009), y Carlson and Ripley, (1997).

Investigadores como Käfer et al., (2020) y Duan et al., (2019) han empleado modelos de validación de LST recuperada de L8 con mediciones directas de campo y reportan desviaciones entre 1,0 y 1,7 °C. Este trabajo logró diferencias entre 1,1 y 1,3 °C empleando termómetros portátiles. Estos resultados sugieren un rendimiento consistente en los puntos de validación asociado al método de compensación atmosférica y el modelo de emisividades  $F_{COVER}$  derivado de S2. Autores como Elmes et al., (2020) y Liu and Li, (2018) han examinado los patrones de cambio térmico urbano del fenómeno SUHI con diferencias similares, por lo que los errores obtenidos en este trabajo se consideran apropiados para los objetivos del estudio.

El resultado del procesamiento térmico de las 37 escenas Landsat permitió detectar la distribución temporal de LST. La Figura 20 muestra la información térmica media de la ciudad de Cartago para el periodo 2001-2020. El promedio de LST fue 20,6 °C.




Figura 20. Comportamiento de LST media de imágenes procesadas 2001-2020

Los resultados de la Figura 20 señalaron que los valores de LST incrementaron durante el periodo de tiempo estudiado. El rango comprendido entre los años 2001-2010 varió desde 17,2 °C hasta 23,2 °C con media de 19,2 °C. En la siguiente década el rango LST entre 2010-2020 varió desde 15,3 °C hasta 25,7 °C con media de 21,9 °C. Al comparar los valores medios de los rangos referidos se detectó una tendencia general de aumento térmico de 2,7 °C entre una década y otra. En la última década la tasa de incremento anual fue de 4,1%. Sin embargo, el aumento revelado de 2,7 °C se encuentra altamente influenciado

por distintos episodios del fenómeno del Niño sobre la región Andina colombiana. De acuerdo con los reportes oficiales de IDEAM durante el periodo de tiempo analizado, este fenómeno ha ocasionado alteraciones de la temperatura entre los años 2003-2004; 2006-2007; y 2014-2016 (Ministerio de Medio Ambiente, 2021). Estos periodos son coincidentes con los valores pico de las temperaturas registradas en la Figura 20. Esto implica que el fenómeno del Niño induce el aumento de radiación solar y cambios en las condiciones de humedad del suelo disminuyendo la reflectividad de la superficie y por tanto, el aumento en LST. Sería interesante emplear modelos estadísticos avanzados para separar los efectos del fenómeno del Niño sobre los efectos causados a la LST por condiciones antropogénicas.

## 5.2 Análisis de los componentes principales

Se aplicó la transformación PCA para analizar los factores ambientales LST, NDBI, NDVI, NDWI, TCB, TCG, TCW, cada uno apilado con 37 bandas que contienen información sobre la continuidad de los grados progresivos de su distribución sobre el paisaje en el periodo 2001-2020. A partir de sus matrices de varianzas/covarianzas se determinaron las cargas factoriales para obtener la cantidad de varianza explicada por cada componente.

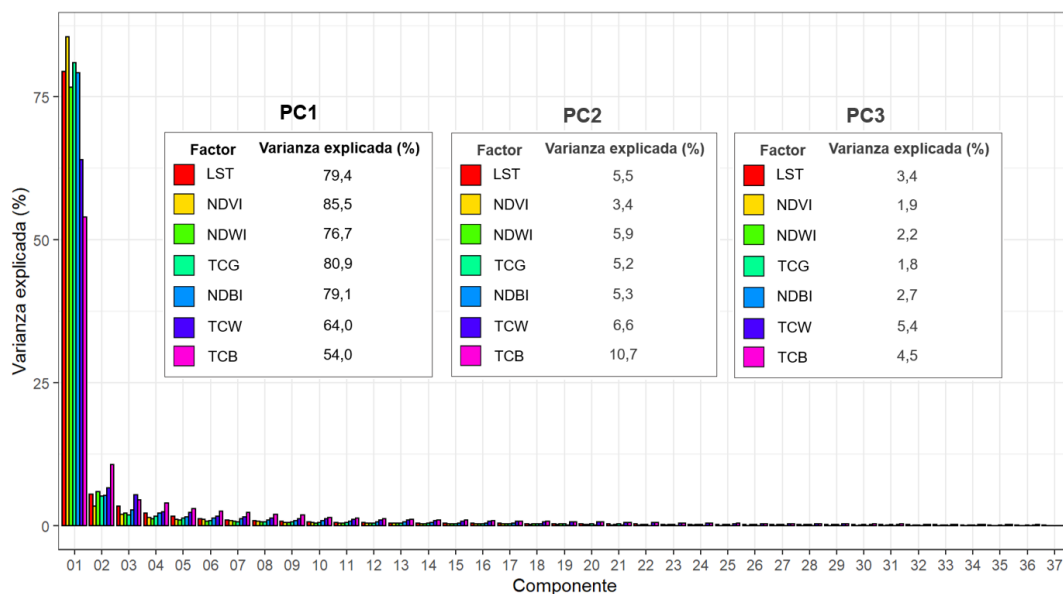
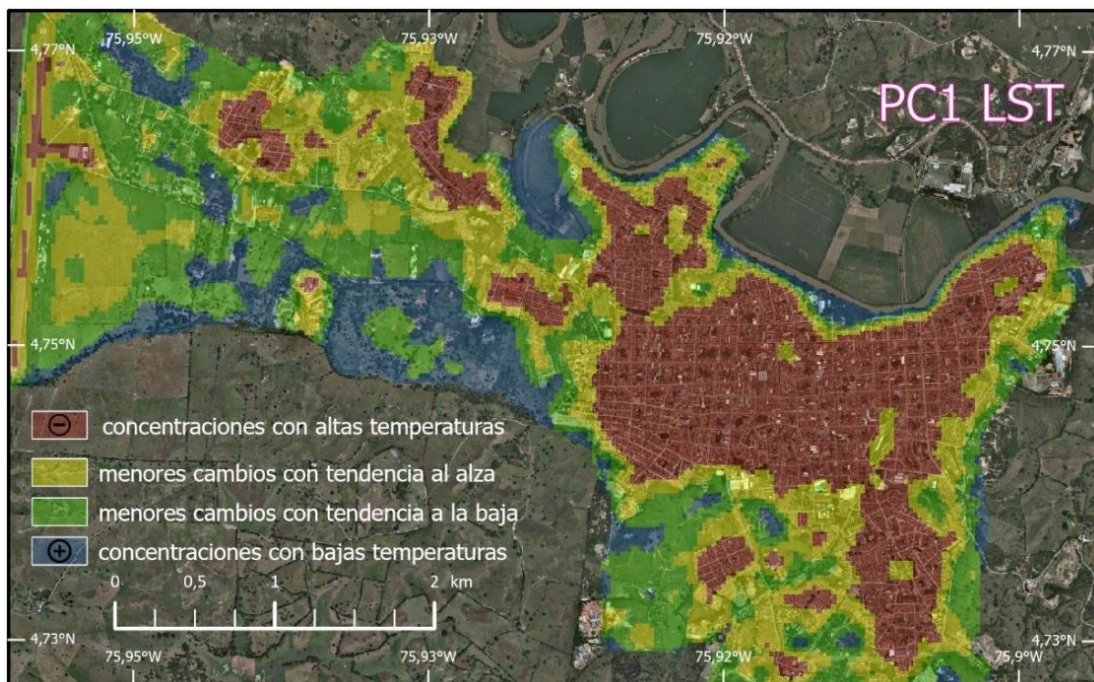


Figura 21. Porción de varianza explicada por factores y componentes principales

La [Figura 21](#) indica que la mayor cantidad de varianza explicada de cada factor se encontró contenida en el PC1. Se puede observar que los PC1 de TCW y TCB proporcionaron menor contribución a la varianza con 64 y 54% respectivamente. El resto de las variables analizadas se encontraron por encima de 76%. En cuanto a la varianza explicada del PC2, TCB alcanzó cerca de 11%, sugiriendo un futuro análisis de sus implicaciones.

Para interpretar espacialmente las tendencias espaciotemporales de cada factor se produjeron mapas con los PC1 obtenidos. Cada mapa se reclasificó en 4 subclases empleando el método de rupturas naturales de Jenks con ArcGIS Pro, los resultados se muestran en las [Figuras 22 a 28](#). El método de Jenks reclasifica valores continuos en clases discretas, con el objeto de facilitar su interpretación. La técnica se soporta en el concepto de que los valores de un conjunto de datos se agrupan de forma natural en diferentes clases, cada una con un rango similar de valores y una mayor homogeneidad interna. El algoritmo se basa en la minimización de la suma de las desviaciones cuadráticas de los valores de cada clase frente a su media para hallar los límites que generan máxima varianza entre clases y la mínima varianza dentro de cada clase ([Rahman et al., 2022](#)).



*Figura 22. Variabilidad térmica 2001–2020*

En este conjunto de mapas (Figuras 22 a 28) los símbolos (+) y (-) representan los valores extremos positivos o negativos del PC1. A continuación, se realiza un análisis cualitativo de los mapas de tendencia espaciotemporales de los factores evaluados.

La Figura 22 enseña el mapa de variabilidad térmica urbano del periodo 2001-2020. Se percibe un cambio gradual desde menores temperaturas en el área perimetral, hasta altas concentraciones de LST en áreas de mayor densidad urbana. Las regiones con menor temperatura se ubican principalmente en zonas cercanas a cuerpos de agua o vegetación frondosa.

Analizando la Figura 23, los cambios de densidad de NDVI de hacia áreas con densidades de construcción media y alta, sugieren variaciones importantes sobre el mapa de tendencia LST (Figura 22). Se observa una influencia significativa de la vegetación frondosa del mapa NDVI en zonas de máxima concentración de bajas temperaturas. La relación LST- NDVI señala que a medida que la densidad de la vegetación aumenta, la temperatura superficial disminuye, ocasionado el enfriamiento radiativo en zonas de alta concentración vegetal.

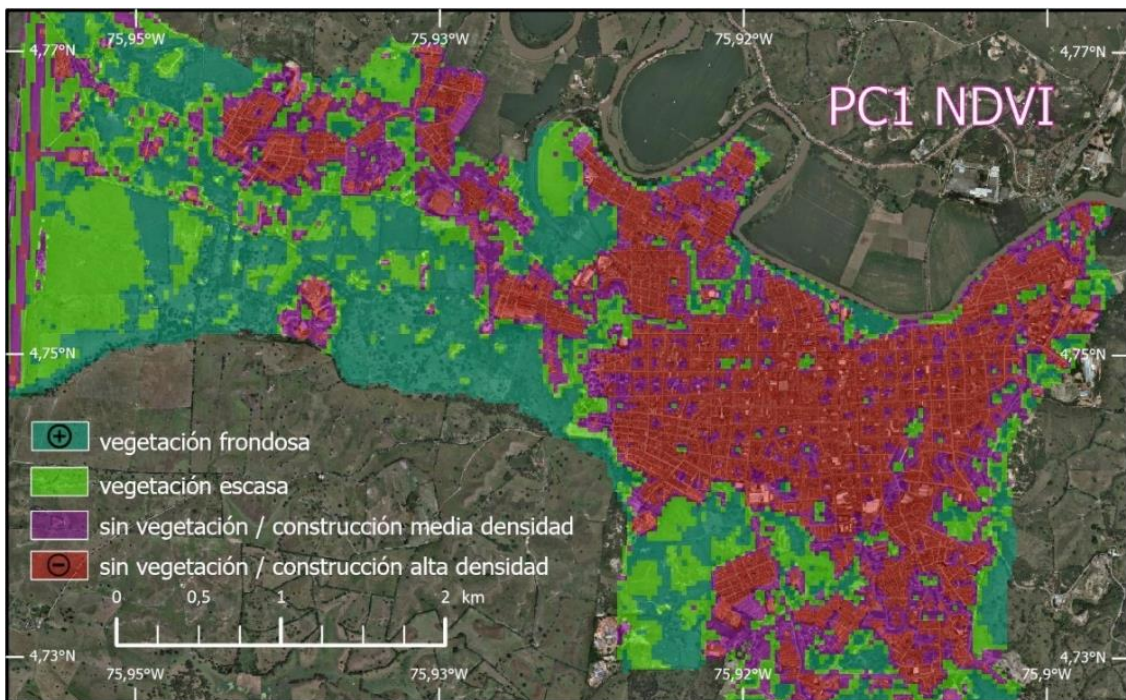
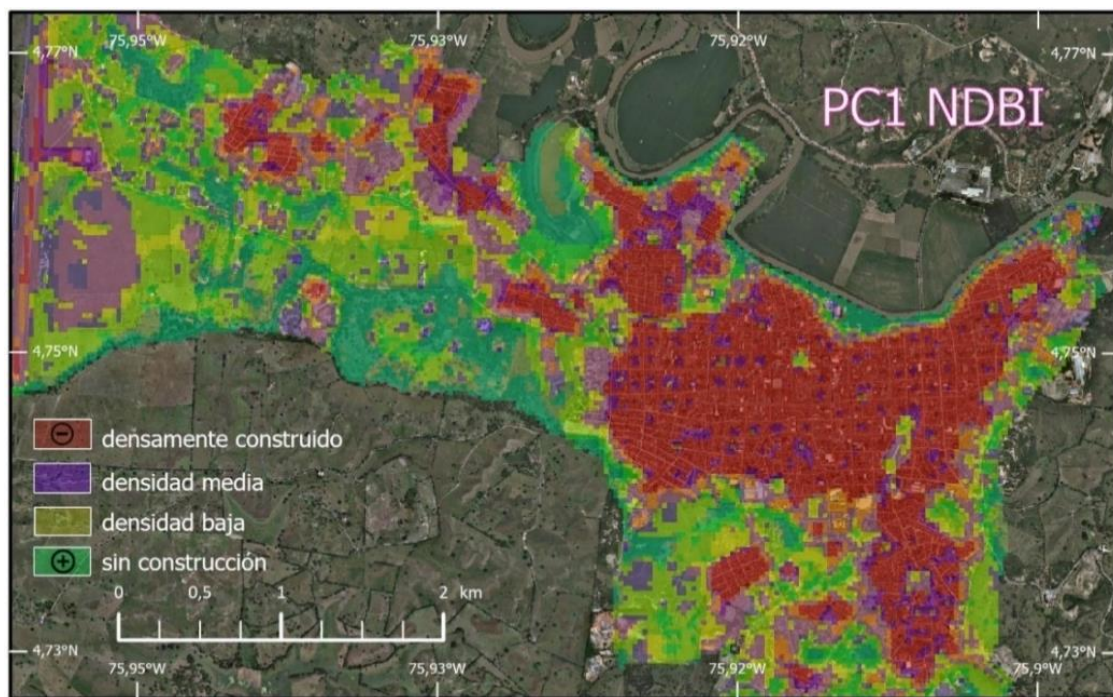


Figura 23. Variabilidad NDVI

Los resultados de la [Figura 24](#) sugieren que las máximas concentraciones de NDBI se ajustan al mapa LST con las áreas construidas de mayor densidad, lo cual revela que estas 2 variables se encuentran estrechamente relacionadas. La variabilidad espacial de esta relación se podría explicar por la complejidad de la geometría urbana y su alta capacidad de almacenamiento calórico, al igual que los materiales de construcción y superficies pavimentadas, que producen aumento térmico de la superficie terrestre. Las áreas identificadas sin construcción son claramente explicadas por la vegetación frondosa del mapa de la [Figura 23](#).



*Figura 24. Variabilidad NDBI*

Las áreas con mayor índice de humedad de la [Figura 25](#) presentan mayor flujo de calor latente comparadas con aquellas áreas extremadamente secas, esto debido al fuerte efecto de la evapotranspiración causando notable disminución de LST. Las áreas identificadas como extremadamente secas señalan relación directa con el mapa NDBI dado que las áreas densamente urbanizadas poseen un alto grado de impermeabilidad, lo que implica que la radiación infrarroja aumenta y por tanto, la temperatura.

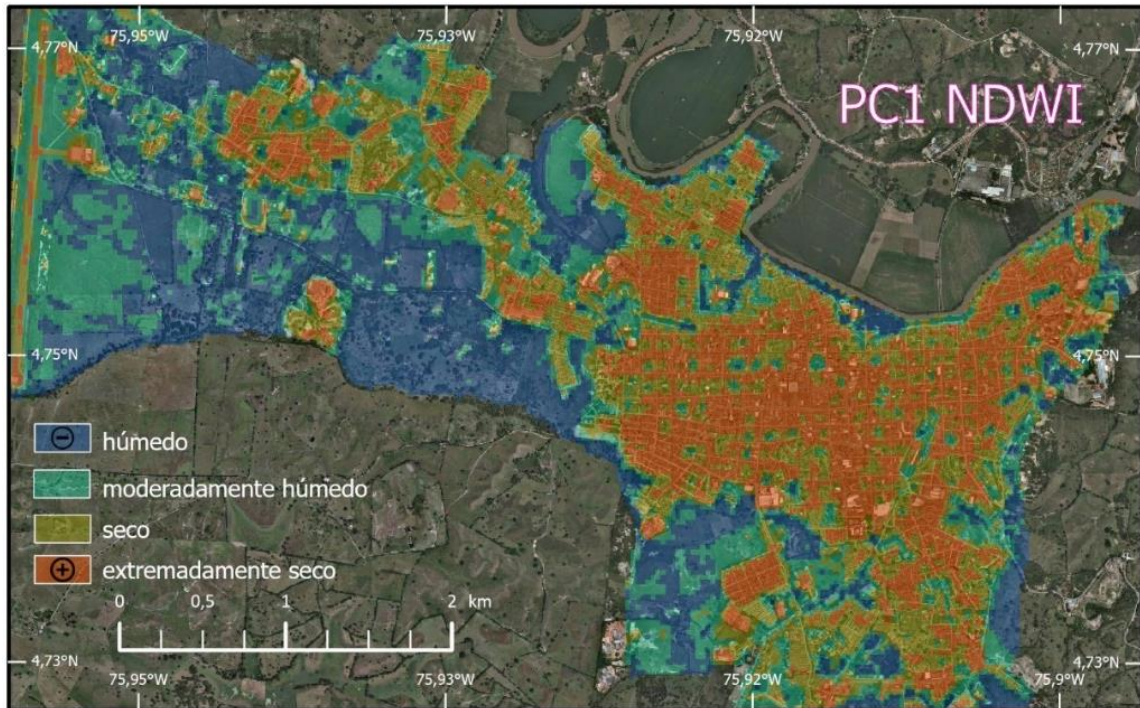


Figura 25. Variabilidad NDWI

Las superficies más brillantes poseen mayor capacidad de reflectividad, lo que reduce la cantidad de energía absorbida por las cubiertas que luego se transformará en calor. El TCB es un índice empleado para cuantificar la cantidad de energía que refleja la superficie, por lo cual se esperaría una relación inversa con la LST. Sin embargo, el mapa TCB de la Figura 26 parece no ajustarse a las características de tendencias de LST, NDVI, NDBI, o NDWI. De acuerdo con la Figura 21, el PC1 TCB presentó el menor porcentaje de explicación de la varianza frente a los factores evaluados. Esto implica que existe una cantidad significativa de variabilidad en los datos (46%) que no está siendo capturada por el PC1. En este caso el PC1 no es una medida suficiente para explicar la tendencia espaciotemporal del TCB. Se necesitan más componentes principales para analizar adecuadamente la variabilidad de estos datos.

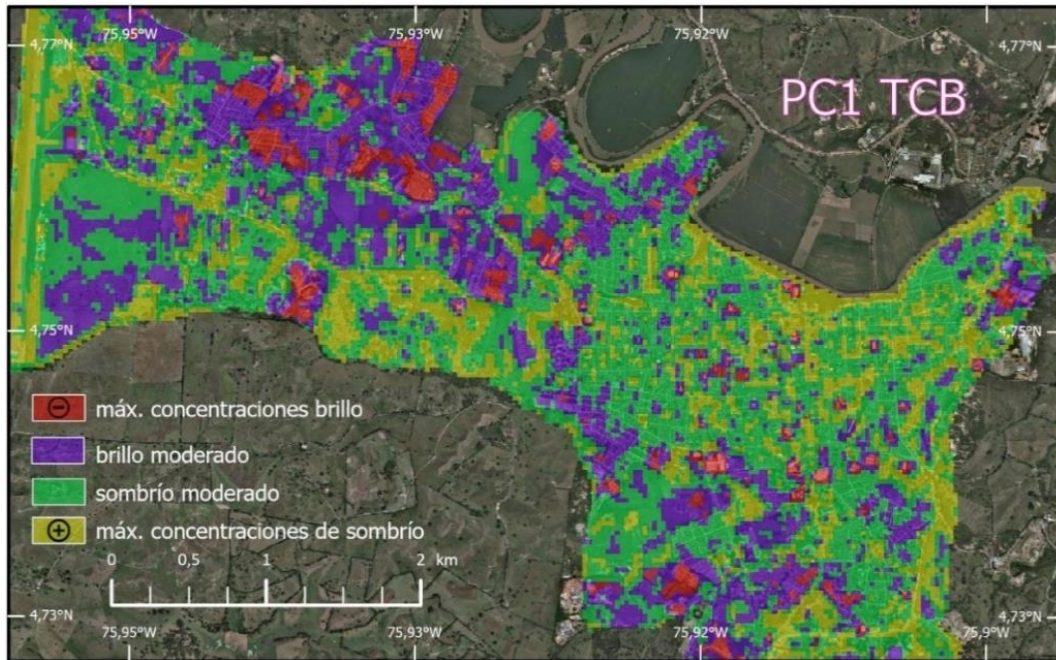


Figura 26. Variabilidad Tasseled Cap – Brillo (TCB)

Los mapas TCG (Figura 27) y NDVI (Figura 23) parecen tener alto grado de similitud, mientras que, las máximas concentraciones de humedad de la Figura 28 sugieren alguna semejanza con el NDWI.

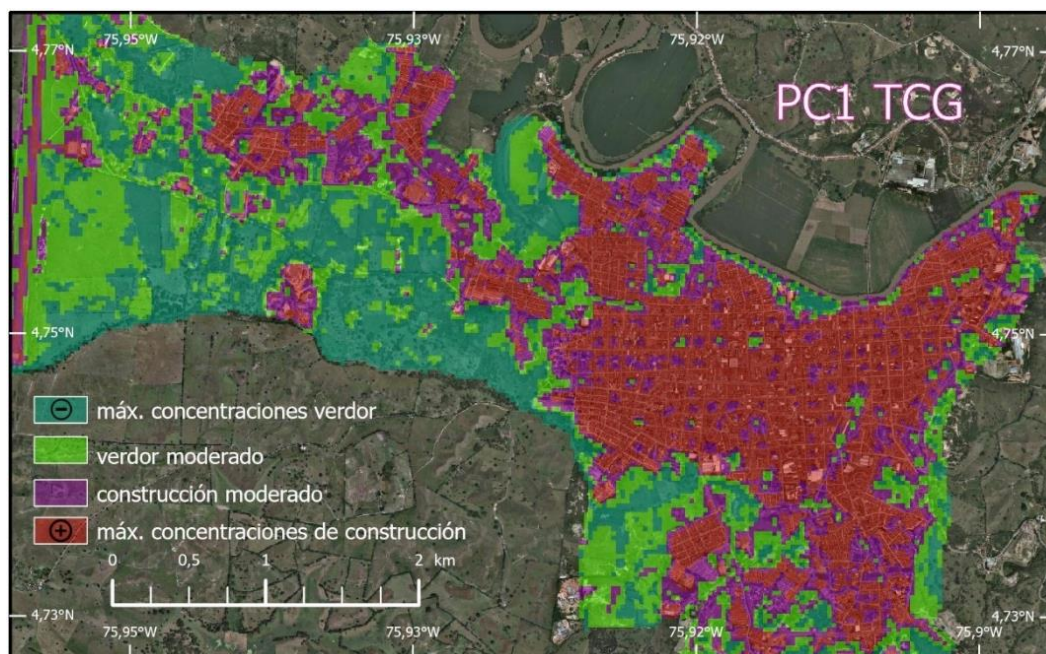


Figura 27. Variabilidad Tasseled Cap – Verdor (TCG)

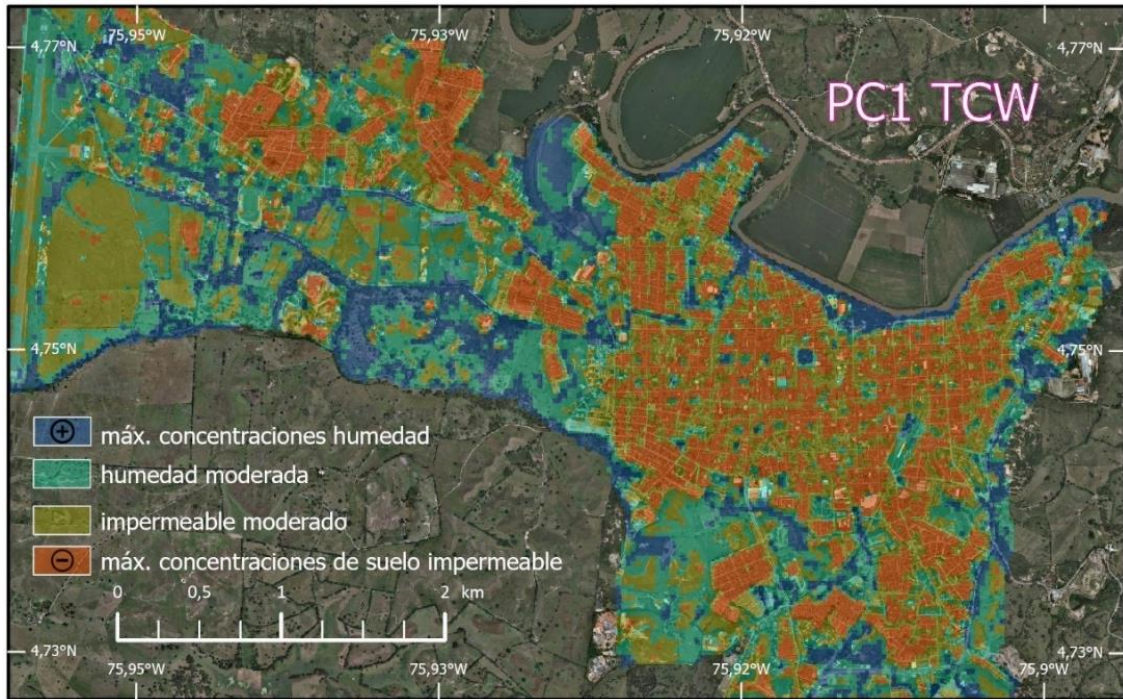


Figura 28. Variabilidad Tasseled Cap – Humedad (TCW)

Los mapas de proximidad del centro urbano (PUC) y de los cuerpos de agua (PW) se presentan en las Figuras 29 y 30. La construcción se puede interpretar como la unidad básica de generación de calor. La cercanía de cada píxel con el centro urbano de la ciudad influye en diversos factores como, la intensidad comercial y de ocupación del suelo que aumenta el efecto de radiación, y la liberación de calor residual de la actividad humana ocasionada por el uso de vehículos que emplean combustibles fósiles. El mapa PUC señala una relación inversa entre la concentración de LST y la distancia al punto central.

Aunque, las áreas con cuerpos de agua en la zona de estudio son limitadas, tienen alta capacidad de captura de calor y generan condiciones térmicas estables que pueden aislar y regular de manera efectiva la temperatura en áreas locales. La absorción de radiación que produce el río *La Vieja* extiende su influencia en un rango de 200 m. Estos mapas de proximidad ayudan a identificar patrones espaciales de LST y a comprender de mejor manera su relación con las características del paisaje urbano.

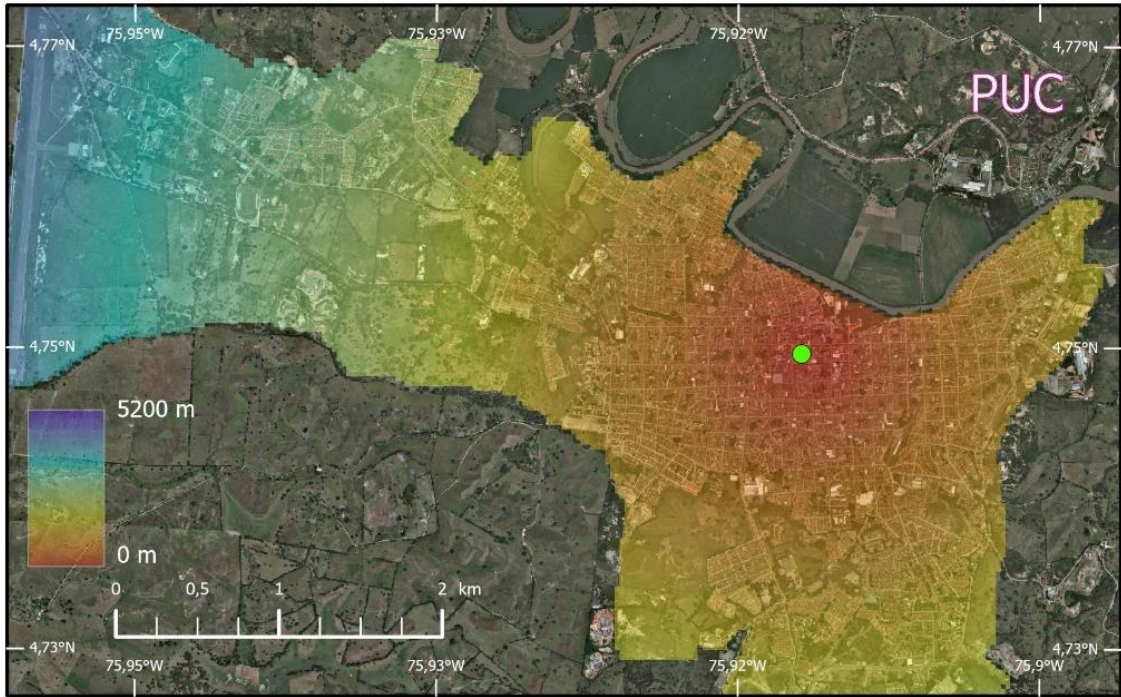


Figura 29. Proximidad al centro urbano (PUC)





Figura 30. Proximidad a los cuerpos de agua (PW)

Notablemente, LST es el resultado de combinar distintos factores impulsores, lo que implica necesario considerar sus efectos combinados. Estas interesantes relaciones se abordarán analíticamente en la próxima sección.

## 5.3 Identificación de factores influyentes de LST

Se analizó el conjunto de datos de los PC1 obtenidos en la sección 5.2 a través de un diagrama de caja y bigotes. La [Figura 31](#) muestra la amplitud de rango de cada factor. En general, no hubo tendencia de sesgo y se evidenció gran cantidad de datos atípicos en TCB y TCW, lo que condujo a que se excluyeron de la modelación MLR. Adicionalmente, dichas variables fueron las de menor contribución a la varianza explicativa de los componentes principales. Dado que NDVI y TCG presentaron alto nivel de correlación ( $R^2=0,98$ ) esta última también fue excluida.



*Figura 31. Diagrama de caja y bigotes. Factores evaluados a través de PCA*

La relación entre LST y sus factores candidatos influyentes (NDBI, NDVI, NDWI, PUC, PW) fue examinada cuantitativamente a través de regresión lineal múltiple (MLR) *stepwise*, empleando el criterio AIC (Akaike's Information Criterion) para la selección de variables. El modelo descartó el factor de proximidad de cuerpos de agua (PW) dado que no logró el nivel de significancia estadística. El coeficiente de determinación  $R^2$  alcanzado sugiere que los factores ambientales considerados explicaron el 82% de la variabilidad en la tendencia térmica. Los factores influyentes de la tendencia multitemporal de LST fueron: NDBI, NDVI, NDWI, y PUC. Sobre esta base, el modelo MLR que representa la variabilidad de LST en términos de variables estadísticamente válidas se describió mediante la siguiente expresión:

$$LST = 0,29 + 0,48 \cdot NDBI + 0,21 \cdot NDVI - 0,61 \cdot NDWI - 0,51 \cdot PUC \quad (23)$$

Los coeficientes del modelo de regresión representan el cambio en LST para 1 unidad de cambio sobre la variable predictora, mantenido constantes el resto de las variables. Los coeficientes estimados, errores estándar, intervalos de confianza, *valores-t* de Student y *valores-p* del modelo MLR se encuentran listados en la [Tabla 11](#). Los  $p < 0,05$  de la [Tabla 11](#) sugieren que las relaciones entre predictores fueron estadísticamente significativas, es decir, no presentaron correlación con la variable dependiente LST. Los coeficientes resultantes del análisis MLR describen el efecto de los predictores sobre LST en el periodo 2001-2020.

*Tabla 11. Resultados ajustados del modelo MLR*

Nombre	Parám.	Coef.	Error estándar	Intervalos de confianza 95%		Valor t	p (>t  0,05 )
				Lím. inf.	Lím. sup.		
	$\beta_0$	0,29	0,01	0,26	0,34	34,79	<0,001
NDBI	$\beta_1$	0,48	0,05	0,21	0,71	9,91	<0,001
NDVI	$\beta_2$	0,21	0,02	0,09	0,24	13,21	<0,001
NDWI	$\beta_3$	-0,61	0,03	-0,77	-0,50	-23,65	<0,001
PUC	$\beta_4$	-0,51	0,01	-0,60	-0,47	-39,60	<0,001

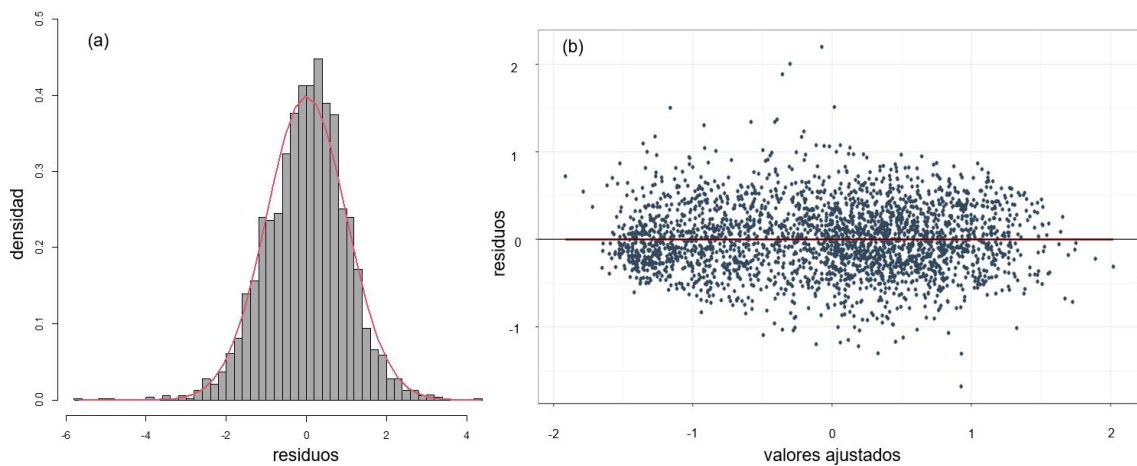
Finalmente, para respaldar la validez del modelo MLR se verificaron los supuestos de autocorrelación, normalidad residual y multicolinealidad. Los resultados se encuentran en la [Tabla 12](#).

*Tabla 12. Contraste de supuestos del modelo MLR*

Autocorrelación		Normalidad		Multicolinealidad (VIF)			
D-W	p-valor	K-S	p-valor	NDBI	NDVI	NDWI	PUC
2,00	>0,05	0,02	>0,05	45,03	9,12	45,75	1,26

Se empleó la prueba Durbin-Watson (D-W) para verificar la independencia entre residuos. El estadístico D-W fue de 2,0 encontrándose en el rango de los valores críticos ( $1,5 < D-W < 2,5$ ) lo que señala la ausencia de autocorrelación. La

normalidad se diagnosticó a través de la prueba de bondad Kolmogórov-Smirnov (K-S), el  $p > 0,05$  sugiere que los residuos proceden de la distribución normal. El análisis realizado a través de la [Figura 32 \(a\)](#) confirmó que los residuos se distribuyeron normalmente. La línea roja en la [Figura 32 \(b\)](#) indica que la variabilidad de los valores ajustados frente a los residuos se mantuvo constante alrededor de 0, confirmando la homogeneidad de la varianza del modelo.

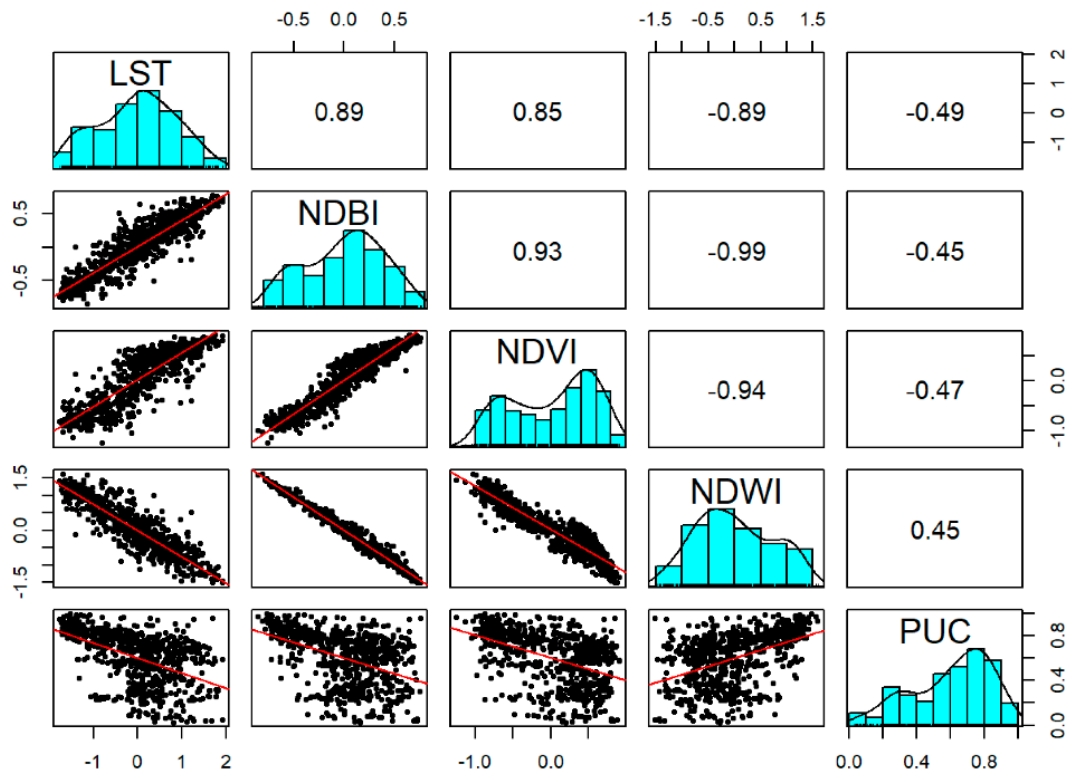


*Figura 32. Análisis gráfico de normalidad residual del modelo MLR*

*(a) Histograma de residuos con ajuste de distribución normal. (b) Variabilidad de residuos.*

En la [Tabla 12](#) se aprecia que los valores VIF de NDBI y NDWI son mayores a 10 superando la tolerancia que ocasiona la multicolinealidad de variables. Esto implica que estas 2 variables deberían ser descartadas, sin embargo, [Szymanowski and Kryza, \(2012\)](#) afirman que las variables que superan esta tolerancia pueden ser consideradas si representan una mejora significativa al modelo de regresión. Además, estos 2 predictores presentan alta relevancia en diversos estudios asociados a LST ([Guha, 2019](#)), ([Onáčillová et al., 2022](#)), ([Y. Li et al., 2022](#)). En el estudio UHI de [Cruz et al., \(2020\)](#) luego de realizar una prueba de multicolinealidad se seleccionaron variables explicativas con VIF entre 50 y 70 para su análisis de regresión. Estos fueron considerados un componente importante para modelar este fenómeno. Estas son las razones para mantener NDBI y NDWI como variables explicativas en este estudio.

Se realizó un análisis de correlación de Pearson para identificar la fuerza de las relaciones entre pares de variables del MLR. Los resultados se presentan en la [Figura 33](#). También se muestran sus histogramas sobre la diagonal principal. El panel inferior bajo la diagonal enseña sus diagramas de dispersión.



*Figura 33. Correlaciones entre los descriptores del modelo*

La relación lineal entre los predictores y la variable de respuesta se validó a través de diagramas de dispersión entre LST y los residuos del modelo. La [Figura 34](#) sugiere que el modelo es lineal dado que no presentó patrones definidos. Los datos se distribuyeron aleatoriamente alrededor de 0.

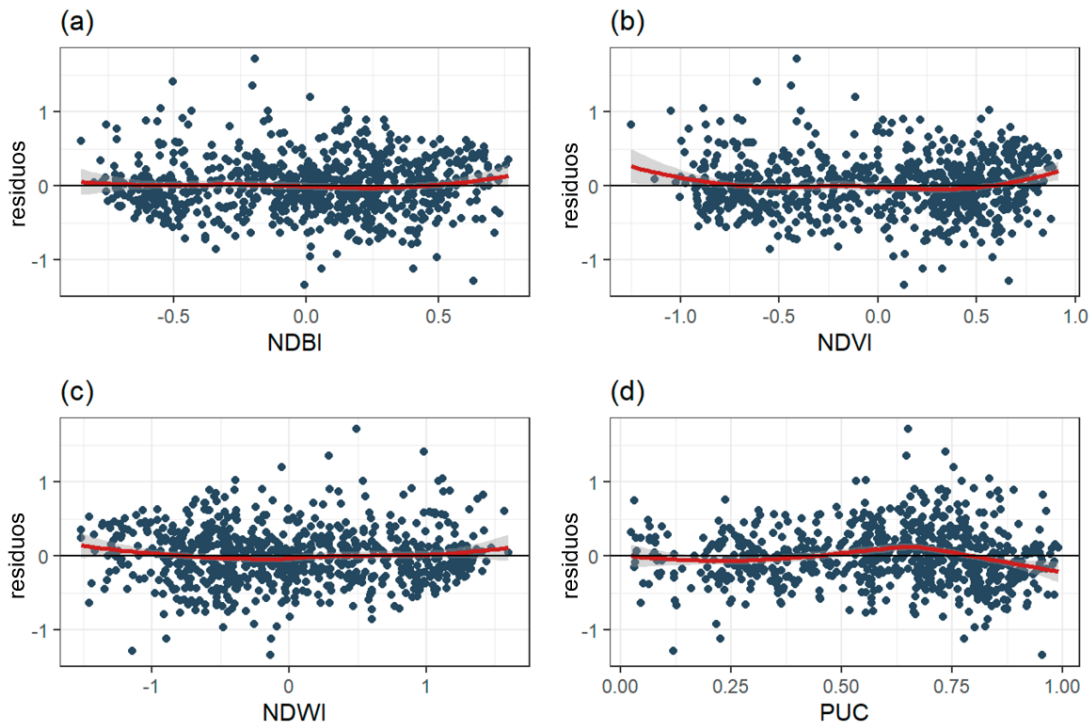


Figura 34. Diagramas de dispersión entre predictores y residuos del MLR

Finalmente, la influencia relativa ( $W_i$ ) de cada variable sobre LST se obtuvo a través de los coeficientes estandarizados del MLR ( $\widehat{w}_i$ ). Estos resultados se presentan en la [Tabla 13](#) donde se observa que los principales factores contribuyentes fueron las variables NDWI y NDBI, seguidos de NDVI y PUC. La [Figura 35](#) muestra las variables en orden de importancia descendente indicando en qué medida influyó cada predictor sobre LST.

Tabla 13. Coeficientes MLR estandarizados e influencia relativa de cada factor

Factor	Coeficientes estandarizados ( $\widehat{w}_i$ )	Influencia relativa ( $W_i$ )
NDBI	0,21	21,38
NDVI	0,13	12,84
NDWI	-0,51	51,46
PUC	-0,14	14,32

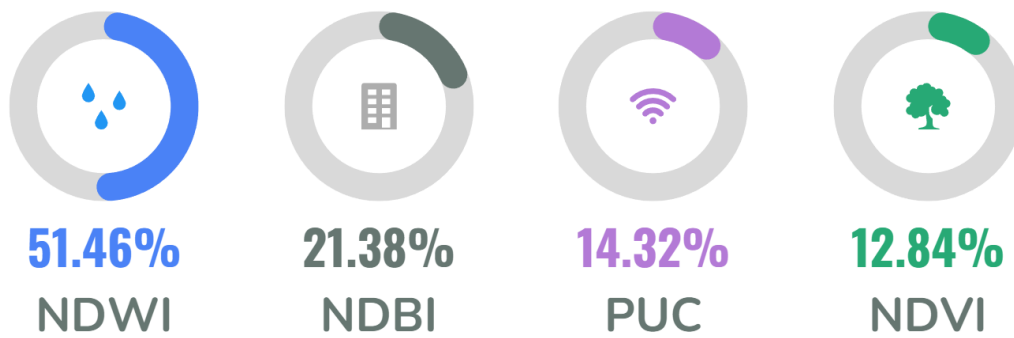


Figura 35. Influencia relativa de factores aportantes a LST

### 5.3.1 Análisis de la modelación estadística MLR

Existen múltiples factores que pueden influir en la formación del fenómeno SUHI y que se encuentran relacionados entre sí. Estudios previos han detectado los principales factores controlantes de LST empleando modelos de regresión y aprendizaje automático en diferentes ciudades. Los hallazgos de esta modelación se ajustaron con estudios que han utilizado técnicas de regresión para cuantificar el impacto de los factores contribuyentes sobre LST (Abir et al., 2021), (Meng et al., 2022). Sin embargo, otros estudios han presentado controladores diferentes de la temperatura (W. Liu et al., 2021), (Yu et al., 2022). La diferencia de los componentes explicativos de LST con los presentados en este trabajo, puede atribuirse a que cada ciudad es única a través de la constitución de sus factores predominantes como sus características topográficas, climáticas, y morfológicas que afectan el albedo, la emisividad y por ende la temperatura. El efecto acumulativo de estos factores resulta en diferentes dinámicas espaciotemporales de SUHI. En el caso de la ciudad de Cartago, la combinación de estos factores de escala local produjo información relevante sobre el mecanismo detrás de la evolución del efecto SUHI. A medida que el forzamiento urbano antropogénico aumenta y la vegetación disminuye, el enfriamiento por evaporación superficial y los flujos de calor latente disminuyen. Las superficies impermeables absorben y almacenan mayores cantidades de energía calórica, que influyen en la temperatura del entorno inmediato y modifican el clima urbano amplificando el efecto de aumento térmico.

En cuanto a las condiciones para asegurar la validez del enfoque MLR se deben abordar varias consideraciones. La multicolinealidad de las variables predictoras y su efecto en el modelo indicaron que los valores VIF de las variables NDWI y NDBI superaron el umbral de 10, lo que las excluiría como explicativas del modelo de regresión. Desde el enfoque estadístico el comportamiento de estas variables es expresado por el de otras variables independientes, sin embargo, al eliminarlas, se estarían obviando variables que desde un enfoque físico son distintas y significativas en análisis SUHI. La eliminación de variables altamente correlacionadas puede beneficiar el resultado general y simplificar el modelo. Sin embargo, tener variables significativas de alta contribución como NDWI y NDBI puede mejorar los productos de predicción, como señalan [Szymanowski and Kryza, \(2012\)](#). Aunque se presentó colinealidad, el coeficiente de determinación y el cumplimiento de supuestos de autocorrelación, normalidad y homocedasticidad de los residuos han denotado un modelo confiable.

Es imperativo cuantificar las relaciones entre los factores contribuyentes para explicar de mejor manera el calor urbano de la ciudad y comprender los mecanismos de formación de SUHI. En consideración a las relaciones directas de la [Figura 33](#) entre LST y sus contribuyentes se observó una fuerte correlación positiva con NDBI. Esto se asocia al alto grado de impermeabilidad de las áreas urbanizadas que al tener menor albedo superficial que las cubiertas naturales, permite mayor absorción de radiación de onda corta aumentando su capacidad de retención calórica. El NDBI describe efectivamente la temperatura.

La [Figura 36](#) muestra un transecto sobre el cual se extrajeron los perfiles LST/NDBI denotando que las máximas temperaturas se produjeron en las áreas de mayor concentración de construcción, y las zonas de menor intensidad coincidieron con parques urbanos que por su cubierta vegetal aumentan los flujos de calor latente y disminuyen la temperatura por su evapotranspiración y sombra, indicando un importante servicio ecosistémico que mejora las condiciones térmicas urbanas. Estudios previos han demostrado que NDBI siempre presenta fuerte correlación positiva con LST ([Guha et al., 2021](#)).

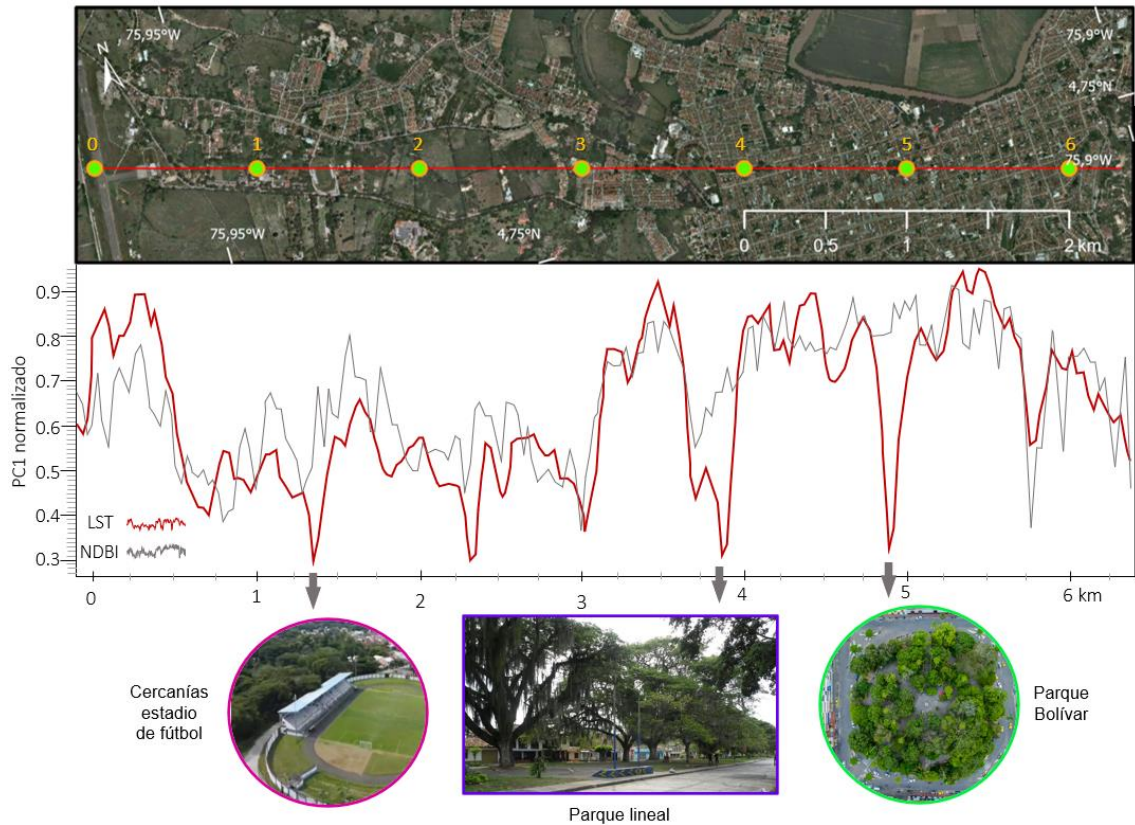


Figura 36. Perfiles LST y NDBI en un transecto urbano

De acuerdo con la Figura 33 existe una fuerte correlación positiva entre LST y NDVI. Esto no sugiere que cuanto mayor sea la cubierta vegetal mayor será la temperatura. Lo anterior se soporta en la escala de representación de dicha figura que está dada en valores del PC1 (positivos y negativos). Los valores positivos o negativos del PC1 sugieren la dirección de correlación entre el componente y la variable. La interpretación de los componentes principales se basa en encontrar qué clases agrupadas están más fuertemente correlacionadas con el componente, es decir, los valores más alejados de 0 en dirección positiva o negativa lo estarán. Los mayores valores positivos del PC1-LST y PC1-NDVI se encontraron en áreas de vegetación frondosa como lo evidencian las Figuras 22 y 23. Por lo anterior, la correlación LST-NDVI en este trabajo será interpretada como negativa.

La fuerte correlación negativa entre LST y NDWI sugiere que la temperatura disminuyó a medida que la humedad aumentó. Así mismo, NDVI y NDWI presentaron alta correlación. La razón está fuertemente asociada con el contenido de humedad del suelo que se presenta mayoritariamente en áreas con vegetación

frondosa, lo que altera el balance energético y causa efectos de variación de la radiación solar. Estos resultados están en línea con los obtenidos por [Aslan and Koc-San, \(2021\)](#) quienes reportaron una fuerte correlación negativa entre dichas variables y LST, sugiriendo su empleo ampliamente en la determinación de estudios SUHI.

La [Figura 36](#) indica que el calor urbano es mitigado por la vegetación frondosa. Sin embargo, la [Figura 35](#) señala que el NDWI tiene mayor influencia relativa que NDVI en la explicación de LST. Una cantidad relacionada con el flujo de calor latente es el vapor de agua atmosférico. La alta correlación entre NDVI y NDWI (0,94) sugiere que la humedad del suelo en áreas con alta densidad de vegetación produce gran cantidad de vapor de agua mitigando la intensidad de LST.

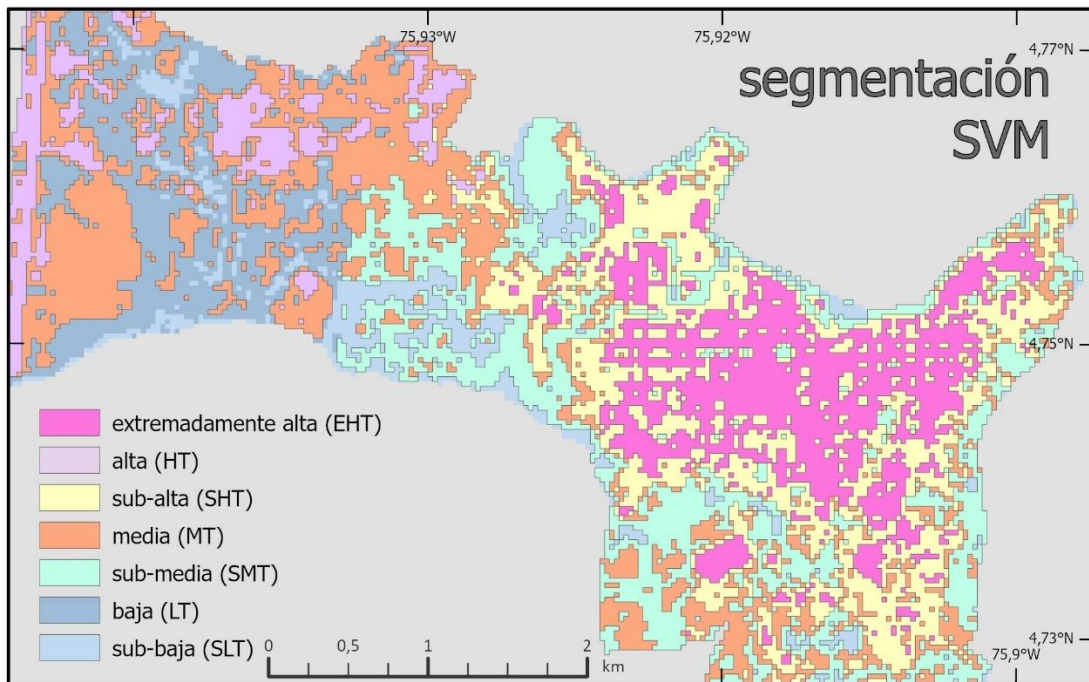
Existe una asociación moderada entre las variables LST y PUC en base al coeficiente de correlación obtenido. La LST aumenta levemente de acuerdo con la proximidad al centro urbano. Esta correlación puede estar asociada a la distribución de la densidad urbana y su infraestructura vial, que frente a la proximidad son las responsables de generar una estructura compleja no bien representada por modelos lineales. Esto sugiere profundizar el impacto de las condiciones geométricas y explorar modelos subyacentes no lineales para analizar la distribución de entornos construidos a nivel de climas urbanos, que revelen un patrón de relación más complejo.

Finalmente, [Mirchooli et al., \(2020\)](#) analizaron las variaciones espaciales entre LST y los índices espectrales NDBI, NDVI y NDWI, empleando métodos de regresión que incluyeron GWR y OLS. Sus resultados señalaron al índice NDWI como el de mayor importancia para caracterizar los cambios sobre LST. Esto se ajusta a los resultados de la [Tabla 13](#) que indica la contribución ponderada de cada factor sobre LST y define a NDWI como el de mayor influencia relativa sobre el modelo de regresión de tendencia térmica.

## 5.4 Modelación SUHI

El fenómeno SUHI depende de las propiedades de las cubiertas terrestres que, combinadas con su capacidad de absorción de energía producen un incremento térmico en la superficie y representan una amenaza para los ecosistemas urbanos. El enfoque de modelación de este trabajo se basó en la segmentación de grupos de píxeles homogéneos que permitieron identificar áreas con distinto potencial térmico. Se probaron 2 algoritmos de aprendizaje automático *Support Vector Machine* (SVM) y *Weighted Naïve Bayes* (WNB) con los que se obtuvieron 2 *mapas de análisis térmico urbano*. Las áreas de entrenamiento se extrajeron del mapa de tendencia LST obtenido en la sección 5.2 y mostrado en la [Figura 22](#). Para este fin se emplearon las 7 clases térmicas definidas por [H. Wang et al., \(2017\)](#) y [Zhao et al., \(2022\)](#) descritas en la [Tabla 9](#). Estas clases se basan en los promedios de LST ( $T_a$ ) y sus desviaciones estándar (SD).

El algoritmo SVM se aplicó sobre los factores influyentes de la tendencia multitemporal de LST. El resultado de la segmentación del modelo SVM es el primer *mapa de análisis térmico urbano* presentado en la [Figura 37](#).



*Figura 37. Mapa térmico urbano - segmentación SVM*

En la segmentación SVM las temperaturas extremadamente altas (EHT) se presentaron en áreas de mayor densidad urbana. En general se exhibió un cambio gradual desde el centro urbano hacia la periferia. Las áreas de densidad media urbana que se mezclaron con vegetación y cuerpos de agua que se asociaron a valores de temperatura media (MT), lo que denota su efecto en la reducción de LST para entornos edificados. Es posible inferir que la densidad de la vegetación funcionó como un factor atenuante de la intensidad térmica al aproximarse a estas áreas. En la periferia y áreas con baja densidad urbanística se encontraron temperaturas bajas (SMT), (LT) y (SLT) a excepción del costado occidental que presentó valores altos (HT) en la pista de aterrizaje del aeropuerto. Se observó un fuerte enlace entre la vegetación densa y los valores de menor intensidad térmica (SLT).

Para llevar a cabo la segmentación con el algoritmo *Weighted Naïve Bayes* (WNB), primero, se obtuvieron las probabilidades *a priori* de cada clase  $P(C_k)$ . Estas fueron el porcentaje de ocupación de los rangos térmicos de la [Tabla 9](#). Luego, se obtuvieron los parámetros de las funciones de mejor ajuste sobre la distribución estadística de cada factor y clase. El tipo de distribución y sus parámetros se indican en la [Tabla 14](#). Las funciones gaussiana y logística mostraron los mejores resultados para las respectivas frecuencias de entrenamiento por clases.

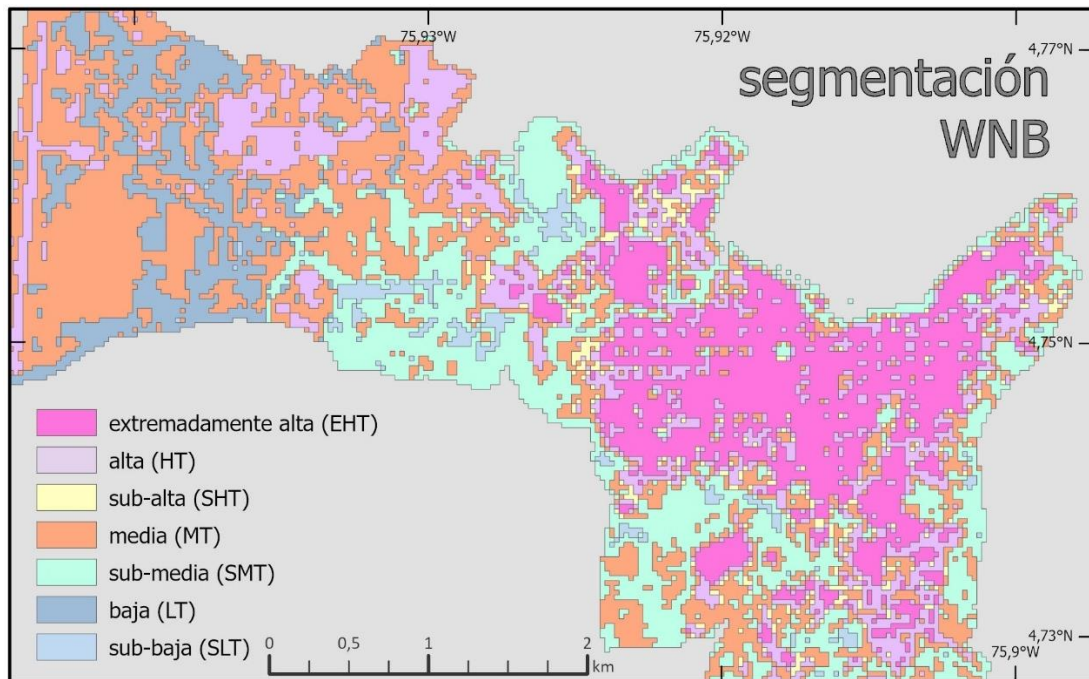
*Tabla 14. Parámetros de funciones de densidad de probabilidad*

Clase	NDBI		NDVI		NDWI		PUC	
EHT	$\mu=-0,69$ •	$\sigma=0,05$ •	$\mu=-0,85$ *	$\sigma=0,09$ *	$\mu=1,27$ *	$\sigma=0,15$ *	$\mu=0,85$ *	$\sigma=0,06$ *
HT	$\mu=-0,41$ •	$\sigma=0,11$ •	$\mu=-0,45$ *	$\sigma=0,31$ *	$a=0,80$ ‡	$b=1,52$ ‡	$\mu=0,35$ *	$\sigma=0,16$ *
SHT	$\mu=-0,40$ •	$\sigma=0,05$ •	$\mu=-0,60$ *	$\sigma=0,16$ *	$a=0,79$ ‡	$b=5,62$ ‡	$\mu=0,80$ *	$\sigma=0,06$ *
MT	$\mu=-0,04$ •	$\sigma=0,06$ •	$\mu=0,21$ •	$\sigma=0,20$ •	$\mu=0,08$ •	$\sigma=0,12$ •	$\mu=0,50$ *	$\sigma=0,17$ *
SMT	$\mu=0,33$ •	$\sigma=0,10$ •	$\mu=0,46$ •	$\sigma=0,13$ •	$\mu=-0,66$ *	$\sigma=0,29$ *	$\mu=0,80$ *	$\sigma=0,06$ *
LT	$\mu=0,36$ •	$\sigma=0,09$ •	$\mu=0,46$ •	$\sigma=0,11$ •	$\mu=-0,66$ *	$\sigma=0,32$ *	$\mu=0,35$ *	$\sigma=0,16$ *
SLT	$\mu=0,67$ *	$\sigma=0,16$ *	$a=0,88$ ‡	$b=11,03$ ‡	$\mu=-1,31$ •	$\sigma=0,19$ •	$\mu=0,85$ *	$\sigma=0,06$ *

De acuerdo con los símbolos las funciones se distribuyeron así: (\*) gaussiana; (•) logística; (‡) weibull.

Finalmente, para entrenar el autómata se calcularon las funciones de densidad de probabilidad (PDF) de cada clase  $C_k$  por cada factor contribuyente (NDBI, NDVI, NDWI, PUC) al tiempo que fueron ponderadas de acuerdo con su

influencia relativa. Esto permitió aplicar la regla de decisión para hallar el argumento de máxima probabilidad *a posteriori*, segmentando así el área de estudio en diferentes unidades de intensidad térmica. El resultado de la segmentación del modelo WNB es el segundo *mapa de análisis térmico urbano* presentado en la [Figura 38](#). La capacidad de ponderación del método WNB permitió tener en cuenta la influencia relativa de cada factor para derivar el producto SUHI. Esta condición no fue posible con el algoritmo SVM.




*Figura 38. Mapa térmico urbano - segmentación WNB*

Comparando los resultados de segmentación de los 2 algoritmos, SVM y WNB la mayoría de las clases encontraron alto nivel de coincidencia. Sin embargo, se percibieron variaciones importantes en la clase SHT (sub-alta). Esto puede estar asociado a diversos factores como, la amplitud estadística del rango de la muestra, los errores en la selección de áreas de entrenamiento, y la influencia de la ponderación de WNB. A continuación, se discuten estos factores.

La clase SHT se presenta como la más sensible en términos de su rango de amplitud estadística con  $\frac{1}{2}$  desviación estándar (SD). Sus valores fluctúan entre  $\frac{1}{2}$  y 1 SD mostrándose como uno de los rangos con menor ancho de banda frente

a rangos como HT y MT que presentan anchos de 1 SD. Esta sensibilidad de rango puede generar áreas mezcladas en los límites de las clases con píxeles identificados como HT y/o MT. La [Figura 39](#) muestra las diferentes amplitudes de los rangos de clasificación de las áreas de entrenamiento extraídos de la [Tabla 9](#). La franja de color amarillo indica la amplitud del rango SHT.



*Figura 39. Amplitudes de rango LST en áreas de entrenamiento*

En la [Tabla 14](#) que señala los parámetros de las funciones de densidad de probabilidad (PDF), se detecta que la clase SHT presentó la mayor desviación (5,62) para el factor NDWI. La [Figura 40](#) indica en color púrpura la función de distribución acumulada de la clase SHT y el factor NDWI. Es notorio su comportamiento dentado lo que dificulta la capacidad de ajuste en su parte central a funciones como Weibull o Normal. Estos saltos en la función se presentan por errores en la recolección de sus áreas de entrenamiento. Se empleó la PDF de la distribución Weibull porque se ajustó levemente mejor que la Normal para el conjunto de datos de entrenamiento de la clase SHT.

Dado que el algoritmo *Weighted Naïve Bayes* (WNB) empleó estas muestras para realizar las predicciones de forma ponderada y que NDWI fue el factor de mayor influencia sobre la temperatura (51,46%), se espera que esta clase presente la menor precisión en su clasificación debido a la combinación de la influencia relativa del factor y su incertidumbre muestral.




Figura 40. Funciones de densidad de probabilidad NDWI-SHT

La modelación empleada busca predecir la ubicación de distintos rangos térmicos, por tal motivo no se dispone de valores futuros con los cuales contrastar tales predicciones. Para validar el rendimiento de la modelación se emplearon los mismos criterios de las áreas de entrenamiento, pero en zonas diferentes, para obtener las matrices de confusión.

Las Tablas 15 y 16 reportan las matrices de confusión, precisiones del usuario (UA) y del productor (PA) de los resultados obtenidos en la clasificación. La Tabla 17 reporta la precisión global y el índice Kappa para SVM y WNB.

Tabla 15. Matriz de confusión segmentación SVM

	EHT	HT	SHT	MT	SMT	LT	SLT	Clasificación general	UA
EHT	19	0	2	0	0	0	0	21	0,90
HT	0	20	0	1	0	0	0	21	0,95
SHT	0	0	21	0	0	0	0	21	1,00
MT	0	0	1	19	1	0	0	21	0,90
SMT	0	0	0	0	20	0	1	21	0,95
LT	0	3	0	2	1	12	3	21	0,57
SLT	0	0	0	0	1	0	20	21	0,95
Clasificación de referencia	19	23	24	22	23	12	24	147	
PA	1,00	0,87	0,88	0,86	0,87	1,00	0,83		

Tabla 16. Matriz de confusión segmentación WNB

	EHT	HT	SHT	MT	SMT	LT	SLT	Clasificación general	UA
EHT	63	0	1	0	0	0	0	64	0,98
HT	0	32	0	1	0	0	0	33	0,97
SHT	0	0	21	6	0	0	0	27	0,78
MT	0	1	0	32	0	0	0	33	0,97
SMT	0	0	0	0	48	0	0	48	1,00
LT	0	0	0	0	0	53	1	54	0,98
SLT	0	0	0	0	2	1	32	35	0,91
Clasificación de referencia	63	33	22	39	50	54	33	294	
PA	1,00	0,97	0,95	0,82	0,96	0,98	0,97		

Tabla 17. Resultados de las métricas de precisión de clasificadores

algoritmo	Índice Kappa	Precisión global
SVM	0,88	0,88
WNB	0,94	0,95

La interpretación visual de los mapas de segmentación térmica producidos en las Figuras 37 y 38 y sus métricas de calidad soportadas en los valores del índice Kappa, SVM: 0,88 y WNB: 0,94 demostraron resultados confiables. Ambos clasificadores detectaron temperaturas extremadamente altas (EHT) en las zonas de mayor densidad urbana. WNB presentó precisiones de clasificación por rangos independientes superiores a SVM. Sin embargo, la clase SHT obtuvo precisión de usuario (UA) de 78%. Esta clase se vio considerablemente influenciada por la amplitud estadística del rango de la muestra, y la amplificación del factor de ponderación WNB sobre los errores en la selección de las áreas de entrenamiento.

El algoritmo *Weighted Naïve Bayes* (WNB) obtuvo mayor homogeneidad en su clasificación demostrado por su precisión global: 0,95 frente a 0,88 de SVM. La diferencia favorable a WNB se explica por el acople de criterios para asignar pesos individuales a cada clase mejorando la calidad del producto segmentado.

Los clasificadores *Naïve Bayes* convencionales consideran que este modelo es aplicable cuando la función de densidad de probabilidad gaussiana está presente en el conjunto de datos (Suh and Jeong, 2022). Sin embargo, Molina et al., (2016), demostraron que la combinación del modelo de distribución de mejor ajuste (no necesariamente gaussiano) y la influencia relativa de cada factor condujo a resultados satisfactorios al aplicar este algoritmo.

Como consecuencia de los resultados de las métricas de calidad evaluadas se eligió el producto segmentado de *Weighted Naïve Bayes* (WNB) como el mapa de análisis térmico, a partir del cual se obtuvo el *mapa de recomendaciones de planificación térmica urbana*, asociando la clase extremadamente alta (EHT) con las islas de calor. Las demás clases se agruparon para generar recomendaciones de adaptación a la regulación térmica. La Figura 41 muestra el *mapa de recomendaciones de planificación térmica urbana*, que categoriza el entorno según un estado específico, sugiriendo un tipo de acción en función de la modelación de este trabajo. Las recomendaciones propuestas se agruparon en 4 categorías así: *intervenir, monitorear, fortalecer y preservar*.

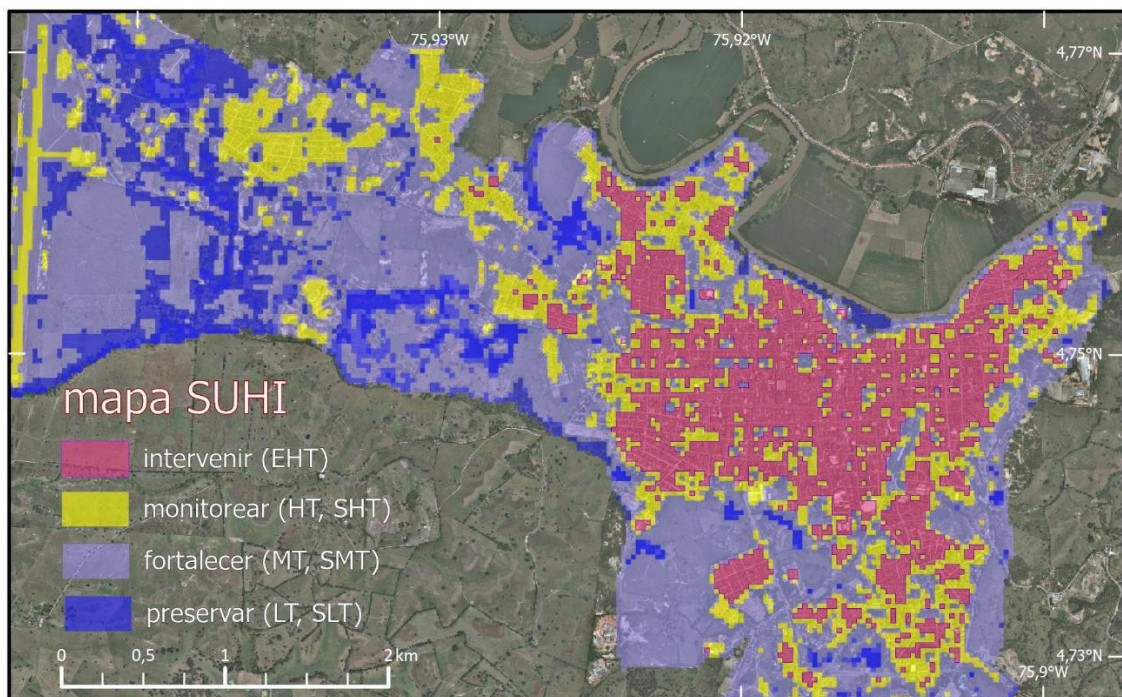


Figura 41. Mapa de recomendaciones de planificación térmica urbana.

La recomendación *intervenir* tiene relación directa con las áreas de máxima concentración térmica (EHT). Estas son zonas críticas identificadas como las islas de calor urbano, que necesitan de acciones inmediatas para regular el alto flujo de calor sensible. La recomendación *monitorear* agrupa las categorías de temperatura *alta* (HT) y *sub-alta* (SHT) señalando las áreas LST que se encontraron entre  $\frac{1}{2}$  y 2 SD, estas deben mantenerse bajo observación e intervención en el mediano plazo, debido a que presentan carga térmica moderada y han indicado algún aumento gradual en su tendencia temporal. La recomendación *fortalecer* reúne las clases *media* (MT) y *sub-media* (SMT), se exhibe en zonas térmicamente neutrales y de bajo índice de densidad de construcción presentando una carga térmica baja. La recomendación *preservar* agrupa las clases *baja* (LT) y *sub-baja* (SLT), enmarcando áreas que se deben proteger por su importancia en la regulación térmica. A continuación, se asocian estas recomendaciones a distintas estrategias de mitigación.

## **5.5 Perspectivas e implicaciones para la planificación urbana**

Las ciudades integran factores socioeconómicos y ecosistemas naturales que enmarcan las actividades humanas ávidas de espacio para su crecimiento. El desplazamiento de los suelos de cultivo y bosques genera una sobrecarga antropogénica al ecosistema ocasionando el desequilibrio radiativo. En una era de cambio climático enmarcada por la presión demográfica, el crecimiento urbano y la contaminación del aire, la elección de un enfoque de desarrollo urbano sostenible basado en la renaturalización se plantea como una solución concreta para la gestión sólida territorial. La búsqueda de alternativas para reconfigurar la infraestructura urbana es una necesidad imperante en nuestra adaptación hacia el calor urbano.

La observación del territorio en espacio y tiempo permite monitorear las dinámicas de los ecosistemas urbanos. La modelación del fenómeno SUHI define una línea base que identifica patrones, puntos críticos y áreas expuestas a diferentes intensidades térmicas. La influencia relativa de los factores aportantes a la temperatura permite a los planificadores del territorio identificar las

variables a priorizar para reconfigurar el medio urbano, destinado recursos específicos y concentrando esfuerzos en la mitigación de efectos adversos. La reducción de los efectos SUHI trae beneficios como la reducción del consumo energético derivado de sistemas de refrigeración, el mejoramiento de los niveles de confort térmico y de la salud humana. Con base en el enfoque de modelación de este trabajo se proponen 4 estados de recomendación térmica que permiten regular las condiciones para mitigar las condiciones térmicas, *intervención, monitoreo, fortalecimiento y preservación*, como una expresión fundamental entre las causas y efectos del ecosistema urbano (Figura 42). Esto se presenta relevante para las implicaciones ambientales en una época de calentamiento global, especialmente en Colombia por su alto grado de vulnerabilidad al cambio climático y otros fenómenos planetarios producidos por el aumento de gases efecto invernadero. A continuación, se formulan las recomendaciones relevantes de acuerdo con las 4 zonas identificadas en el *mapa de planificación térmica urbana*.

Las áreas designadas como de *intervención* corresponden al centro de la ciudad y muestran tendencia de alta densidad poblacional y edificaciones antiguas. Es altamente recomendado hacer la reposición de tejados de cemento convencionales a ‘tejados frescos’ que controlan la absorción de calor durante el día y su emisión durante la noche, como sugieren [Mushore et al., \(2022\)](#). Acrecentar las áreas de vegetación es una manera efectiva de mitigar el aumento de LST en áreas de alto estrés térmico, sin embargo, por la alta densidad de construcción estas áreas no cuentan con el espacio físico disponible para su implantación. El desarrollo sostenible requiere de transformaciones significativas en los espacios urbanizados para reconfigurar el centro de la ciudad. Una medida interesante que permite la reducción del calor antropogénico es la restricción del tránsito de vehículos privados y la limitación al acceso de zonas específicas. La movilidad de vehículos particulares se puede sustituir por transporte público o bicicleta. Estas medidas ya se han implementado en otras ciudades. El modelo de supermanzanas desarrollado inicialmente para la ciudad de Barcelona España propone unidades de 3x3 manzanas que se peatonalizan alrededor de una calle envolvente. Según [Mueller et al., \(2020\)](#) este modelo puede reducir la temperatura urbana entre 1 y 2 °C. La supermanzana busca la reducción del espacio que tradicionalmente ha sido asignado a los automóviles, y fomentar otros usos alternativos vegetalmente revitalizados ([Eggimann, 2022](#)). Este

modelo es altamente adaptable a diferentes contextos urbanos, incluso en ciudades pequeñas con tipologías constructivas como la de Cartago. Si bien es necesario realizar ajustes según las características de cada ciudad, su filosofía es la creación de espacios peatonales amigables y la promoción de la movilidad sostenible.

En el contexto de la transformación hacia ciudades adaptables a la variabilidad climática, la integración de la vegetación es la respuesta para proteger los ecosistemas urbanos. De acuerdo con [Wujeska-Klaue and Pfautsch, \(2020\)](#) la sombra de árboles frondosos de entre 10 y 20 m de altura, produce un fuerte impacto de mitigación disminuyendo la temperatura en 1,1 °C. El efecto de disminución térmica de la evaporación y sombra de árboles tiene alta variación que depende de las especies y la densidad del dosel ([Rahman et al., 2015](#)).

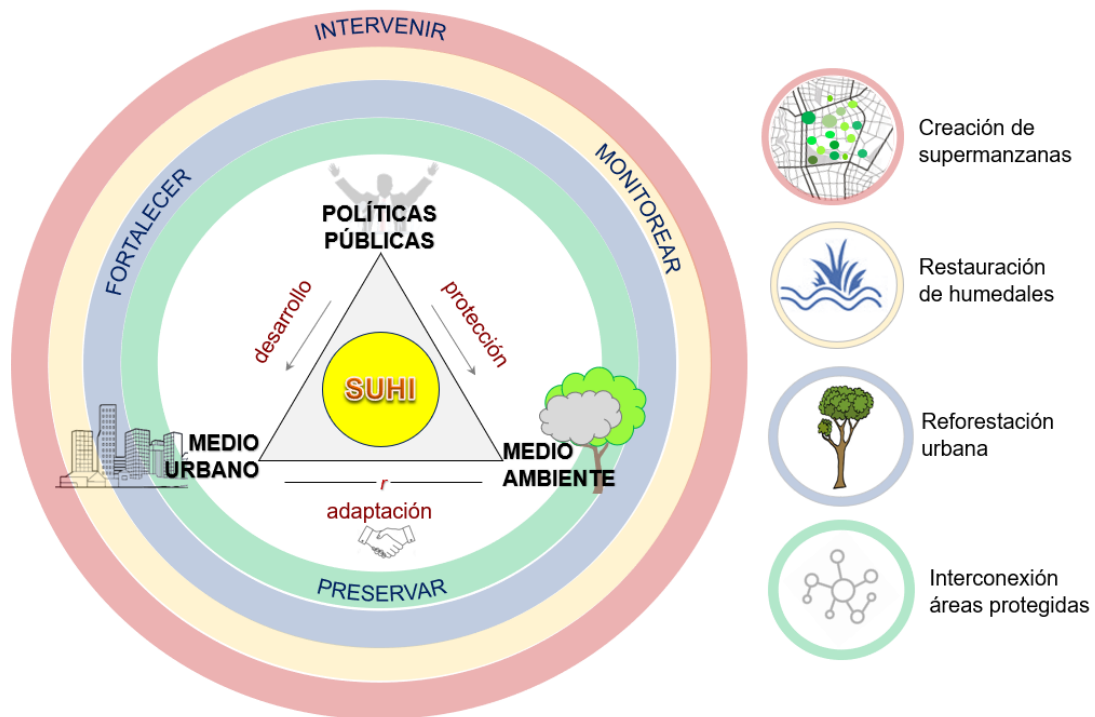


Figura 42. Recomendaciones de adaptación para la regulación térmica urbana

Las áreas identificadas como de *monitoreo*, deben implementar el mantenimiento de cuerpos de agua y áreas con vegetación, favoreciendo el

intercambio energético entre las distintas cubiertas. El riego con agua de lluvia canalizada a través de sistemas de alcantarillado pluvial puede utilizarse como contribución a la restauración y fortalecimiento de humedales urbanos. Además, los humedales ofrecen un hábitat importante para especies vegetales y animales, brindando acceso a espacios naturales en áreas que están dominadas por el entorno construido.

Las áreas señaladas como de *fortalecimiento*, muestran intensidad térmica media y están asociadas al crecimiento urbano. La morfología de estas áreas debe integrar espacios verdes que permitan una mayor infiltración y enfriamiento del agua (Grilo et al., 2020). Una alternativa es el uso de separadores viales con árboles de gran follaje y raíces que no debiliten la infraestructura existente. La sombra de las hojas proporciona el principal efecto de enfriamiento logrado por la vegetación, pues genera un bloqueo para que la radiación solar no incida directamente en la superficie. Se logra un enfriamiento adicional cuando la radiación absorbida por la vegetación se disipa a través de la transpiración de las hojas y la evaporación del medio de crecimiento (Hayes et al., 2022). Es más productivo revitalizar y ampliar áreas de espacios verdes existentes en lugar de construir nuevas áreas pequeñas (Peng et al., 2021). En general, se recomienda el uso de materiales de construcción altamente reflectantes, reduciendo la cantidad de radiación solar absorbida por la superficie, como, por ejemplo, el uso de pavimentos frescos sugeridos por U.S. Environmental Protection Agency, (2012). Estudios de simulación de Vásquez-Álvarez et al., (2022) señalan que reemplazar pavimentos asfálticos por pavimentos de hormigón, logra reducir la LST hasta 3 °C en su área de influencia.

Finalmente, las áreas marcadas como de *preservación*, contiene la mayor cantidad de cubierta vegetal, son fundamentales para la conservación de la biodiversidad y juegan un papel importante en el ecosistema urbano por su enfriamiento evaporativo generando una carga térmica altamente negativa. Como resultado su temperatura es la de menor intensidad. Estas áreas reducen las emisiones de dióxido de carbono, convirtiéndose en espacios que disminuyen la carga antropogénica producida por diversas actividades económicas, y generan regulación térmica. Además, presentan gran potencial para el ecoturismo. El aumento del tamaño de estas áreas, a través de la conectividad de sus hábitats, puede mejorar las condiciones de paisajes térmicos fragmentados.

“Solo los disciplinados en la vida son libres. Si no eres disciplinado, eres un esclavo de tus estados de ánimo y tus pasiones” —dice *Eliud Kipchoge*, el mejor maratonista del mundo—

# CAPÍTULO 6

## CONCLUSIONES

**RESUMEN:** *En este capítulo se presentan las conclusiones más relevantes que surgen de esta investigación. La sección 6.1 señala las respuestas a los objetivos específicos planteados en el desarrollo del trabajo. La sección comienza con la identificación de la fuente de emisividad de mejor ajuste de los 3 modelos evaluados frente a la recuperación de LST, empleando un algoritmo monocanal sobre las imágenes L8/TIRS B10. Luego, refiere los factores ambientales que describen la LST con sus contribuciones ponderadas. Finalmente, se destaca la importancia de integrar la influencia relativa de los controladores de LST al algoritmo de aprendizaje automático WNB en la elaboración del mapa de recomendaciones térmicas. Luego, la sección 6.2 señala de manera específica las contribuciones de esta Tesis Doctoral. Después, la sección 6.3 expone las principales limitaciones del estudio asociadas a la fuente de los datos, la selección de variables explicativas y la modelación estadística. Subsecuentemente, se hace mención de la línea de investigación naciente producto de este trabajo. Finalmente, la sección 6.4 expone la difusión de resultados como un medio efectivo para que se haga uso de la metodología expuesta y los resultados del proyecto.*

## 6.1 Respuesta a objetivos específicos y preguntas de investigación

La identificación de los patrones de distribución de LST representa un papel importante en la adaptación y mitigación de los efectos adversos al fenómeno SUHI. El objetivo general de esta investigación consistió en caracterizar dicho fenómeno bajo un enfoque que integró técnicas de teledetección, modelación estadística, y algoritmos de aprendizaje automático, como medio para contribuir con las dinámicas socioambientales de planificación y gestión territorial urbana sostenible al gobierno local. Para lograr este objetivo se dio respuesta a 5 objetivos específicos y 3 preguntas de investigación. A continuación, se presenta un resumen de los resultados y la conclusión de cada objetivo específico, integrando las respuestas a las preguntas de investigación planteadas.

**OBJETIVO ESPECÍFICO 1.** *Contrastar el comportamiento de LST a partir de distintos modelos de emisividad (valores de referencia de diferentes autores (CBEM), el ASTER GEDv3, y,  $F_{COVER}$  propuesto por Valor and Caselles, (1996)).*

Dado que la temperatura y la emisividad son interdependientes y se influyen mutuamente, uno de los grandes desafíos en la recuperación de LST desde sensores remotos es la obtención de valores de emisividad precisos. En este sentido, LSE debe conocerse para recuperar de manera precisa la LST a partir de mediciones de radiancia. En esta investigación se evaluaron distintos modelos de emisividad en la obtención de LST desde imágenes satelitales. Se ensamblaron 30 termómetros de portátiles para obtener mediciones directas de temperatura que se emplearon como valores de contraste. Los termómetros se dispusieron en diferentes cubiertas durante 2 campañas de medición simultáneas al paso del satélite Landsat 8 OLI/TIRS. De los 3 modelos de LSE evaluados, el modelo original propuesto  $F_{COVER}$  produjo las menores desviaciones (valores entre 1,1 y 1,3 °C) frente a los registros de temperatura medidos de forma directa en campo. El acople entre Landsat 8 OLI/TIRS banda 10 y LSE desde el modelo  $F_{COVER}$  derivado de Sentinel-2 en la recuperación de LST, produjo resultados de mayor precisión y homogeneidad que los producidos por métodos convencionales. Estas desviaciones se consideraron suficiente para proceder con el cálculo de LST

y la aplicación de técnicas estadísticas conducentes al análisis de la variabilidad térmica y la modelación del fenómeno SUHI en el área de estudio.

La importancia de este contraste de emisividades radica en su sensibilidad para producir diferentes valores de LST, lo que puede afectar la precisión y confiabilidad de los valores recuperados, por tanto, la interpretación de los resultados.

**OBJETIVO ESPECÍFICO 2.** *Calcular la LST usando imágenes multiespectrales de Landsat 5 TM, 7 ETM+, 8 OLI/TIRS y Sentinel 2-MSI a partir de la implementación de un algoritmo monocanal.*

La temperatura de la superficie terrestre es el parámetro fundamental en el análisis del fenómeno SUHI. La LST es la clave para comprender el proceso de intercambio energético entre la Tierra y la atmósfera. Las alteraciones en este intercambio generan el forzamiento radiativo que ocasiona el desbalance en la ecuación de energía superficial, haciendo que la temperatura de las áreas urbanas presente diferencias significativas respecto de la de sus áreas rurales circundantes. En esta investigación se recuperó la LST a través de un algoritmo monocanal empleando 48 imágenes multiespectrales de las plataformas Landsat y Sentinel, sobre la ciudad colombiana de Cartago durante el periodo 2001-2020. Los resultados señalaron que los valores de LST incrementaron durante el periodo de tiempo analizado.

Como resultado ligado a este objetivo, se produjo el mapa de tendencia variabilidad térmica que señala gran importancia para detectar de manera detallada los patrones de distribución de LST, permitiendo una mejor comprensión de los procesos que influyen en la distribución térmica.

**OBJETIVO ESPECÍFICO 3.** *Estimar la tendencia temporal de factores ambientales como NDVI, NDBI, NDWI, y la transformación Tasseled Cap, para definir su relación e influencia relativa sobre la LST.*

Los factores influyentes de la LST son diversos y cambiantes de una ciudad a otra debido a la heterogeneidad de sus sistemas urbanos. El aumento poblacional, la transformación a gran escala de la vegetación por zonas altamente impermeables, y la concentración de actividades humanas desestabilizan los ecosistemas e influyen en la LST a través de la regulación del clima local y la transferencia de calor antropogénico. Las interacciones de estos factores se hacen complejas dado que su contribución se da en diferentes proporciones que definen en gran medida la distribución espacial de la temperatura. Para obtener la variación espaciotemporal de los factores ambientales mencionados en el objetivo específico, se empleó la técnica análisis de componentes principales (PCA) que permitió detectar a través del PC1 información explícita sobre la continuidad de los grados progresivos de su distribución en el paisaje para el periodo 2001-2020. Luego, se aplicó un modelo de regresión lineal múltiple (MLR) para valorar los factores y su influencia relativa sobre la temperatura. Se encontró que los factores más influyentes para determinar la intensidad térmica fueron, NDWI con una contribución de 52%, NDBI con 21%, PUC con 14%, y NDVI con 13%, los demás factores evaluados fueron excluidos por diversos motivos como, presencia masiva de datos atípicos o por no lograr los niveles de significancia estadística.

Con lo anterior se da cumplimiento al objetivo específico número 3, y respuesta a las 2 primeras preguntas de investigación (*¿Cuáles son los factores dominantes del exceso de temperatura urbana en el área de estudio?, y ¿Cuál es la tasa de contribución de cada factor?*). Determinar los factores de exceso térmico permite comprender las causas subyacentes al fenómeno SUHI para priorizar acciones y enfocar los recursos en las áreas de mayor impacto.

**OBJETIVO ESPECÍFICO 4.** *Proponer un modelo del fenómeno SUHI que integre técnicas estadísticas y algoritmos de aprendizaje automático, para segmentar el espacio en regiones de diferente intensidad térmica.*

Para modelar el fenómeno SUHI se requiere una estructura computacional que permite comprender la compleja interacción de los factores ambientales controlantes de la temperatura, y que permita identificar zonas con distinto

potencial térmico. La integración de los métodos de aprendizaje automático con los amplios inventarios satelitales de Landsat y Sentinel han mostrado resultados sólidos en el rendimiento potencial de los clasificadores. En esta investigación se compararon 2 algoritmos de aprendizaje automático *Support Vector Machine* (SVM) y *Weighted Naïve Bayes* (WNB), para buscar mayor eficiencia en el reconocimiento de patrones y la segmentación de imágenes térmicas. El primero no contempla la contribución ponderada de los factores influyentes de LST, mientras que el segundo sí lo hace. Ambos clasificadores dieron resultados confiables, respaldados por el índice Kappa SVM: 0,88 y WNB: 0,94. Sin embargo, las características de heterogeneidad de la superficie, afectan las contribuciones relativas de cada factor que influye en la LST. La asignación de estas contribuciones en las áreas de entrenamiento del algoritmo WNB produjo resultados satisfactorios con una precisión global de 95% lo que demostró que el enfoque propuesto es superior a SVM. Por lo anterior comentado se cumple el objetivo propuesto y responder a la última pregunta de investigación: *(¿Es posible integrar la importancia relativa de cada factor, en un algoritmo de aprendizaje automático, para buscar un mejor resultado de segmentación térmica, que el obtenido con algoritmos que no ponderen dichos factores?)*

El producto principal de esta investigación es el modelo metodológico propuesto para caracterizar el fenómeno SUHI. Aunque los resultados se presentan para una zona de estudio específica, el modelo es aplicable en otras áreas urbanas debido a su capacidad para considerar la importancia relativa de las variables de entrenamiento. Esto se logra a través de la programación del autómata empleando WNB, que modela el mapa de recomendaciones de planificación térmica urbana. La fiabilidad del modelo demostró resultados satisfactorios para asegurar su capacidad de generalización.

**OBJETIVO ESPECÍFICO 5.** *Proponer recomendaciones de mitigación sobre las áreas afectadas.*

La rápida urbanización y los efectos del calentamiento global están causando efectos profundos en los asentamientos urbanos y en el bienestar de sus habitantes. Se proyecta que el 70% de la población humana vivirá en áreas urbanas para el año 2050. La Organización Mundial de la Salud estima que el aumento de las temperaturas ha provocado más de 150.000 muertes por año.

Estos problemas ambientales son considerados factores centrales de Objetivos de Desarrollo Sostenible de las Naciones Unidas. El estudio del fenómeno SUHI ha despertado gran interés en la comunidad científica buscando su caracterización altamente ligada a la complejidad de la configuración urbana, con el fin de hallar estrategias que puedan mitigar sus efectos adversos. Esta investigación demostró la idoneidad de los algoritmos de aprendizaje automático para mapear las intensidades térmicas, proporcionando descripciones espacialmente explícitas de la distribución de las islas de calor urbano. Como resultado de la caracterización del fenómeno en este trabajo se produjo el mapa de recomendaciones de planificación térmica agrupadas en las categorías, intervenir, monitorear, fortalecer, y preservar. En cada categoría se han formulado recomendaciones que buscan regular las condiciones biofísicas del territorio para mitigar los efectos del fenómeno. Las recomendaciones incluyen, la restauración de humedales, la reforestación urbana, la interconexión de áreas protegidas, y la creación de supermanzanas como estrategia de diseño urbano para fomentar la movilidad sostenible y fortalecer la calidad de vida de sus habitantes.

La caracterización del fenómeno SUHI contribuye al desarrollo de acciones locales y cuantificables que permiten abordar los desafíos globales del ODS-11 desde el enfoque térmico, para lograr asentamientos urbanos resilientes y sostenibles, que definen sus propias estrategias de mitigación y adaptación en el rediseño de sus ciudades.

## **6.2 Contribuciones**

Si bien el cambio es un aspecto constante en los ecosistemas, los factores urbanos antropogénicos inducidos por el ser humano están forzando al estrés por agotamiento de recursos naturales y una peligrosa incapacidad regenerativa a nivel local, regional y mundial. La emisión continua de gases efecto invernadero está ocasionando cambios en los ecosistemas naturales y humanos, haciendo que los modelos climáticos reporten serios aumentos de la temperatura. Varias plataformas satelitales de observación de la Tierra se encuentran disponibles a la comunidad científica, con información que mide variables biofísicas y diversos

índices que brindan una oportunidad única para estudiar estos impactos y detectar las variaciones espaciotemporales de LST.

Esta investigación mostró que los métodos basados en sensores remotos y aprendizaje automático tienen gran potencial para detectar cambios, tendencias y patrones de la temperatura que experimenta el territorio. El mapeo de las variaciones térmicas es fundamental para caracterizar las condiciones ambientales y promover ciudades sostenibles, sin embargo, las características de heterogeneidad de la superficie, sugieren que las contribuciones de los factores que explican la temperatura se dan en diferentes proporciones. Los algoritmos de aprendizaje automático de paquetes comerciales, presentan limitaciones para asociar la influencia relativa de sus variables de entrenamiento. Lo que aporta de novedoso esta investigación de otras de modelación térmica, es la aplicación del algoritmo *Weighted Naïve Bayes* (WNB) para detectar el fenómeno SUHI teniendo en cuenta los distintos aportes de las variables empleadas en el entrenamiento del autómat, lo cual no ha sido explorado previamente en la literatura especializada. De camino a lograr este objetivo se presentó un modelo original que acopló imágenes L8 y S2-MSI para recuperar valores precisos de LST a través de la variable  $F_{COVER}$ , derivada desde imágenes Sentinel-2 empleando el procesador biofísico del software SNAP. Así mismo, se implementó PCA como técnica estadística para encontrar los patrones espaciotemporales de LST y sus descriptores a través de la varianza explicada en el PC1. Estos resultados se consideran una métrica valiosa para comprender el comportamiento térmico de la superficie terrestre y sus propiedades físicas. Finalmente, la implementación del algoritmo WNB fue apropiada para los fines de la investigación, porque se logró adaptar la influencia relativa de cada factor consiguiendo una mejor segmentación que la obtenida por modelos que no contemplan estas ponderaciones. Los resultados de la segmentación permitieron definir 4 acciones propuestas *intervenir, monitorear, fortalecer, y preservar* a partir de la obtención del mapa de recomendaciones de planificación térmica urbana, que derivó sugerencias específicas para que los planificadores del territorio tomen decisiones racionales con soporte científico y promuevan el desarrollo sostenible de la ciudad.

## 6.3 Limitaciones y futuras líneas de investigación

Los resultados de este trabajo definieron un marco integral sólido para modelar el fenómeno SUHI empleando la variabilidad de LST explicada desde diversos factores influyentes. Sin embargo, aún existen ciertas limitaciones derivadas de (i) la fuente de los datos de teledetección, (ii) la selección de variables y (iii) la modelación estadística.

(i) Las imágenes térmicas infrarrojas fueron proporcionadas por diferentes sensores de la plataforma Landsat que presentan alta resolución espacial, sin embargo, su resolución temporal tiene un período orbital 16 días. Para garantizar la calidad de los datos se seleccionaron escenas con índice de nubosidad < 5%. Estas condiciones restringieron los datos empleados en el procesamiento a 37 imágenes, lo que representa una limitación considerable en la definición de tendencias espaciotemporales de LST para un periodo de 20 años.

(ii) En este estudio se seleccionaron los descriptores para explicar la variabilidad de LST, abarcando factores naturales y antropogénicos, pero, existen numerosos componentes que afectan la LST con mecanismos internos complejos. Sería muy interesante la inclusión de factores multidimensionales, como la densidad y altura de la construcción (Meng et al., 2022). En este trabajo se realizó el análisis de proximidad de cada celda con el centro urbano (PUC), sin embargo, se podría mejorar su enfoque evaluando las condiciones geométricas de la ciudad. La inclusión del albedo como variable física podría ayudar a comprender de mejor forma el intercambio de energía superficial. Así mismo, factores socio-económicos como la densidad poblacional, y el producto interno bruto han sido probadas como variables efectivas determinantes de SUHI (Li et al., 2020). Incluir estos factores en la modelación podría hacer que el trabajo futuro presente mayor solidez informativa.

(iii) También es necesario investigar la relación de LST y sus descriptores con modelos estadísticos no lineales, pues el contraste entre modelos permitiría una alternativa de selección a aquel de mejor ajuste.

Como producto de esta Tesis Doctoral, se plantea la creación de una línea de investigación en *modelación y monitoreo de fenómenos biofísicos* que busca la

sostenibilidad ambiental del territorio, y cuyo objeto de estudio es *la temperatura de la superficie terrestre* como un indicador de la redistribución de la energía en la interfase tierra-atmósfera. De esta manera se contribuye al desarrollo científico local, proporcionando nuevos enfoques que conducen a un avance progresivo de la sociedad. Bajo esta línea de investigación y buscando mayor profundidad en los productos derivados de este trabajo, se avanzará hacia el desarrollo de modelos predictivos térmicos que integren la importancia relativa de sus variables bajo algoritmos de aprendizaje automático, integrando autómatas celulares y cadenas de Markov, que permitan advertir sobre las consecuencias de los cambios ambientales, que modificarán las condiciones térmicas a las que se verá expuesta la población. Estos experimentos de modelización deberían permitir que se altere una variable y se pueda analizar su influencia en el clima urbano mientras se mantienen constantes las demás, para comprender cuánto calor urbano se logra reducir o amplificar si se modifican sus factores controladores.

## 6.4 Difusión de resultados

Los resultados parciales de esta tesis han sido presentados en 2 conferencias internacionales y 1 artículo publicado en una revista indexada incluida en el catálogo *Journal Citation Reports JCR (Q1)*, referenciados así:

Difusión en conferencias:

Garzón, J., Molina, I., & Velasco, J. (2021). Análisis espaciotemporal del fenómeno islas de calor urbano y su relación con factores biofísicos extraídos de imágenes multiespectrales usando técnicas PCA-MLR. *Encuentro Internacional de educación en ingeniería*. Cartagena, Colombia. 21-24 sept. 2021. <https://doi.org/10.26507/ponencia.1567>. Adicionalmente, en este evento se aceptaron 1 poster y 1 artículo con el resumen extendido de la ponencia mediante proceso de revisión por pares según lo establecido por el comité organizador. El artículo se encuentra disponible en: <https://acofipapers.org/index.php/eiei/article/view/1567>

Garzón, J., Molina, I., & Velasco, J. (2022). Utilización de imágenes multiespectrales para caracterizar el fenómeno de isla de calor urbano a escala local: estudio de caso del municipio de Cartago, departamento del Valle del Cauca. *Semana Geomática Internacional 2022, 9<sup>na</sup> edición*. Bogotá, Colombia. 14-17 jun. 2022. <https://beta.igac.gov.co/9na-semana-geomatica>

Difusión en artículos:

1. Garzón, J.; Molina, I.; Velasco, J.; Calabia, A. A Remote Sensing Approach for Surface Urban Heat Island Modeling in a Tropical Colombian City Using Regression Analysis and Machine Learning Algorithms. *Remote Sens.* 2021, 13, 4256. <https://doi.org/10.3390/rs13214256>.

El artículo se encuentra disponible en: <https://www.mdpi.com/2072-4292/13/21/4256>

“En la ciencia la única verdad sagrada, es que no hay verdades sagradas”

Carl Sagan (1934 – 1996)

# CAPÍTULO 7

## BIBLIOGRAFÍA

**RESUMEN:** *A continuación, se relacionan 277 fuentes consultadas como parte integral en la escritura de esta tesis. El listado se ha generado a través del gestor bibliográfico de uso libre Mendeley en su versión de escritorio. Se incluyeron artículos de revistas de alto impacto, actas de conferencia, libros, capítulos de libro, documentos técnicos, páginas web, y tesis doctorales. Mayoritariamente, se consultaron artículos científicos publicados en las revistas Remote Sensing, Remote Sensing of Environment, International Journal of Remote Sensing, y ISPRS Journal of Photogrammetry and Remote Sensing. Los autores más citados en esta investigación fueron J.A. Sobrino, Juan C. Jiménez-Muñoz, Mohammad Karimi Firozjaei, Feng Chen, y Qingyan Meng.*

- Abate, N., Elfadaly, A., Masini, N., 2020. Multitemporal 2016-2018 Sentinel-2 Data Enhancement for Landscape Archaeology : The Case Study of the Foggia Province, Southern Italy. *Remote Sens.* 12, 1309.
- Abir, F.A., Ahmmed, S., Sarker, S.H., Fahim, A.U., 2021. Thermal and ecological assessment based on land surface temperature and quantifying multivariate controlling factors in Bogura, Bangladesh. *Heliyon* 7, e08012. <https://doi.org/10.1016/j.heliyon.2021.e08012>
- Ahmed, B., Kamruzzaman, M.D., Zhu, X., Shahinoor Rahman, M.D., Choi, K., 2013. Simulating land cover changes and their impacts on land surface temperature in dhaka, bangladesh. *Remote Sens.* 5, 5969–5998. <https://doi.org/10.3390/rs5115969>
- Akodéwou, A., Oszwald, J., Saïdi, S., Gazull, L., Akpavi, S., Akpagana, K., Gond, V., 2020. Land use and land cover dynamics analysis of the Togodo protected area and its surroundings in Southeastern Togo, West Africa. *Sustainability* 12, 5439. <https://doi.org/10.3390/su12135439>
- Almulhim, A.I., Bibri, S.E., Sharifi, A., Ahmad, S., Almatar, K.M., 2022. Emerging Trends and Knowledge Structures of Urbanization and Environmental Sustainability: A Regional Perspective. *Sustainability* 14, 13195. <https://doi.org/10.3390/su142013195>
- Alves, E., Anjos, M., Galvani, E., 2020. Surface Urban Heat Island in Middle City : Spatial and Temporal Characteristics. *Urban Sci.* 4, 24–26. <https://doi.org/10.3390/urbansci4040054>
- Arellano, B., Roca, J., 2021. Remote sensing and night time urban heat Island. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* 43, 15–22. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-15-2021>
- Asadi, A., Arefi, H., Fathipoor, H., 2020. Simulation of green roofs and their potential mitigating effects on the urban heat island using an artificial neural network: A case study in Austin, Texas. *Adv. Sp. Res.* 66, 1846–1862. <https://doi.org/10.1016/j.asr.2020.06.039>
- Aslan, N., Koc-San, D., 2021. The use of land cover indices for rapid surface urban heat island detection from multi-temporal landsat imageries. *ISPRS Int. J. Geo-Information* 10, 416. <https://doi.org/10.3390/IJGI10060416>

- Athukorala, D., Murayama, Y., 2021. Urban heat island formation in greater cairo: Spatio-temporal analysis of daytime and nighttime land surface temperatures along the urban-rural gradient. *Remote Sens.* 13, 1396. <https://doi.org/10.3390/rs13071396>
- Avraham, M., Nemirovsky, J., Blank, T., Golan, G., Nemirovsky, Y., 2022. Toward an Accurate IR Remote Sensing of Body Temperature Radiometer Based on a Novel IR Sensing System Dubbed Digital TMOS. *Micromachines* 13, 703. <https://doi.org/10.3390/mi13050703>
- Ayanlade, A., Aigbiremolen, M.I., Oladosu, O.R., 2021. Variations in urban land surface temperature intensity over four cities in different ecological zones. *Sci. Rep.* 11, 20537. <https://doi.org/10.1038/s41598-021-99693-z>
- Azam, M., Maeng, S.J., Kim, H.S., Lee, S.W., Lee, J.E., 2018. Spatial and temporal trend analysis of precipitation and drought in South Korea. *Water* 10, 765. <https://doi.org/10.3390/w10060765>
- Baig, M.H.A., Zhang, L., Shuai, T., Tong, Q., 2014. Derivation of a tasselled cap transformation based on Landsat 8 at-satellite reflectance. *Remote Sens. Lett.* 5, 423–431. <https://doi.org/10.1080/2150704X.2014.915434>
- Baqa, M.F., Lu, L., Chen, F., Nawaz-Ul-huda, S., Pan, L., Tariq, A., Qureshi, S., Li, B., Li, Q., 2022. Characterizing Spatiotemporal Variations in the Urban Thermal Environment Related to Land Cover Changes in Karachi, Pakistan, from 2000 to 2020. *Remote Sens.* 14, 2164. <https://doi.org/10.3390/rs14092164>
- Barca, E., Castrignanò, A., Ruggieri, S., Rinaldi, M., 2020. A new supervised classifier exploiting spectral-spatial information in the Bayesian framework. *Int. J. Appl. Earth Obs. Geoinf.* 86, 101990. <https://doi.org/10.1016/j.jag.2019.101990>
- Barros, W.K.P., Barbosa, M.T., Dias, L.A., Fernandes, M.A.C., 2022. Fully Parallel Proposal of Naive Bayes on FPGA. *Electronics* 11, 2565. <https://doi.org/10.3390/electronics11162565>
- Barsi, J.A., Schott, J.R., Palluconi, F.D., Hook, S.J., 2005. Validation of a web-based atmospheric correction tool for single thermal band instruments, in: *Earth Observing Systems X*. SPIE, San Diego, CA, USA, p. 58820E. <https://doi.org/10.1117/12.619990>

- Bechtel, B., Alexander, P.J., Böhner, J., Ching, J., Conrad, O., Feddema, J., Mills, G., See, L., Stewart, I., 2015. Mapping local climate zones for a worldwide database of the form and function of cities. *ISPRS Int. J. Geo-Information* 4, 199–219. <https://doi.org/10.3390/ijgi4010199>
- Bechtel, B., Demuzere, M., Mills, G., Zhan, W., Sismanidis, P., Small, C., Voogt, J., 2019. SUHI analysis using Local Climate Zones—A comparison of 50 cities. *Urban Clim.* 28, 100451. <https://doi.org/10.1016/j.uclim.2019.01.005>
- Bektas Balcik, F., Ergene, E.M., 2016. Determining the impacts of land cover/use categories on land surface temperature using Landsat8-OLI, in: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Prague, Czech Republic, pp. 251–256. <https://doi.org/10.5194/isprsarchives-XLI-B8-251-2016>
- Benz, U.C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS J. Photogramm. Remote Sens.* 58, 239–258. <https://doi.org/10.1016/j.isprsjprs.2003.10.002>
- Brown, O.B., Minnett, P.J., Evans, R., Kearns, E., Kilpatrick, K., Kumar, A., Sikorski, R., Závody, A., 1999. MODIS Infrared Sea Surface Temperature Algorithm Algorithm Theoretical Basis Document; Version 2.0, University of Miami. Miami, FL, USA.
- Carlson, T.N., Ripley, D.A., 1997. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sens. Environ.* 62, 241–252. [https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1)
- Caselles, E., Valor, E., Abad, F., Caselles, V., 2012. Automatic classification-based generation of thermal infrared land surface emissivity maps using AATSR data over Europe. *Remote Sens. Environ.* 124, 321–333. <https://doi.org/10.1016/j.rse.2012.05.024>
- Čeplová, N., Kalusová, V., Lososová, Z., 2017. Effects of settlement size, urban heat island and habitat type on urban plant biodiversity. *Landsc. Urban Plan.* 159, 15–22. <https://doi.org/10.1016/j.landurbplan.2016.11.004>
- Chakraborty, T., Hsu, A., Manya, D., Sheriff, G., 2020. A spatially explicit surface urban heat island database for the United States: Characterization, uncertainties, and possible applications. *ISPRS J. Photogramm. Remote Sens.*

168, 74–88. <https://doi.org/10.1016/j.isprsjprs.2020.07.021>

- Chakraborty, T.C., Lee, X., Ermida, S., Zhan, W., 2021. On the land emissivity assumption and Landsat-derived surface urban heat islands: A global analysis. *Remote Sens. Environ.* 265, 112682. <https://doi.org/10.1016/j.rse.2021.112682>
- Chander, G., Markham, B.L., Helder, D.L., 2009. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sens. Environ.* 113, 893–903. <https://doi.org/10.1016/j.rse.2009.01.007>
- Chang, J.M.H., Lam, Y.F., Lau, S.P.W., Wong, W.K., 2021. Development of fine-scale spatiotemporal temperature forecast model with urban climatology and geomorphometry in Hong Kong. *Urban Clim.* 37, 100816. <https://doi.org/10.1016/j.uclim.2021.100816>
- Chapman, S., Watson, J.E.M., Salazar, A., Thatcher, M., McAlpine, C.A., 2017. The impact of urbanization and climate change on urban temperatures: a systematic review. *Landsc. Ecol.* 32, 1921–1935. <https://doi.org/10.1007/s10980-017-0561-4>
- Chen, F., Yang, S., Su, Z., He, B., 2015. A new single-channel method for estimating land surface temperature based on the image inherent information: The HJ-1B case. *ISPRS J. Photogramm. Remote Sens.* 101, 80–88. <https://doi.org/10.1016/j.isprsjprs.2014.11.008>
- Chen, F., Zhao, X., Ye, H., Hu, H., 2011. Retrieving land surface temperature from Landsat TM using different atmospheric products as ancillary data, in: *ICSDM 2011 - Proceedings 2011 IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services*. Fuzhou, China, pp. 421–426. <https://doi.org/10.1109/ICSDM.2011.5969079>
- Chen, Q., Cheng, Q., Chen, Y., Li, K., Wang, D., Cao, S., 2021. The influence of sky view factor on daytime and nighttime urban land surface temperature in different spatial-temporal scales: A case study of Beijing. *Remote Sens.* 13, 4117. <https://doi.org/10.3390/rs13204117>
- Chen, X., Feng, L., 2018. Remote sensing of lakes' water environment, in: Liang, S. (Ed.), *Comprehensive Remote Sensing*. Elsevier, pp. 249–277. <https://doi.org/10.1016/B978-0-12-409548-9.10408-7>

- Chen, Y., Zheng, B., Hu, Y., 2020. Mapping local climate zones using arcGIS-based method and exploring land surface temperature characteristics in Chenzhou, China. *Sustainability* 12, 2974. <https://doi.org/10.3390/su12072974>
- Cotlier, G.I., Jimenez, J.C., 2022. The Extreme Heat Wave over Western North America in 2021: An Assessment by Means of Land Surface Temperature. *Remote Sens.* 14, 561. <https://doi.org/10.3390/rs14030561>
- Crist, E.P., 1985. A TM Tasseled Cap equivalent transformation for reflectance factor data. *Remote Sens. Environ.* 17, 301–306. [https://doi.org/10.1016/0034-4257\(85\)90102-6](https://doi.org/10.1016/0034-4257(85)90102-6)
- Cristóbal, J., Jiménez-Muñoz, J.C., Sobrino, J.A., Ninyerola, M., Pons, X., 2009. Improvements in land surface temperature retrieval from the Landsat series thermal band using water vapor and air temperature. *J. Geophys. Res.* 114, D08103. <https://doi.org/10.1029/2008JD010616>
- Cruz, J.A., Santos, J.A., Blanco, A., 2020. Spatial disaggregation of Landsat-derived land surface temperature over a heterogeneous urban landscape using planetscope image derivatives. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch. XLIII*, 115–122. <https://doi.org/10.5194/isprs-archives-XLIII-B5-2020-115-2020>
- CUHK, 2011. Urban Climatic Map and Standards for Wind Environment - Feasibility Study. Hong Kong.
- CVC, DAGMA, CIAT, Alcaldia de Santiago de Cali, 2015. Identificación de Zonas y Formulación de Propuestas para el Tratamiento de Islas de Calor Municipio de Santiago de Cali, Corporación Autónoma Regional del Valle del Cauca, Centro Internacional de Agricultura Tropical, Departamento Administrativo de Gestión del Medio Ambiente. Cali, Valle del Cauca.
- DANE. Departamento Administrativo Nacional de Estadística, 2018. DANE. Información para todos [WWW Document]. URL <https://www.dane.gov.co/> (accessed 12.12.20).
- Dang, B., Liu, Y., Lyu, H., Zhou, X., Du, W., Xuan, C., Xing, P., 2023. Assessment of Urban Climate Environment and Configuration of Ventilation Corridor : A Refined Study in Xi'an. *J. Meteorol. Res.* 36, 914–930. <https://doi.org/10.1007/s13351-022-2035-0.1>

- Dash, P., 2005. Land Surface Temperature and Emissivity Retrieval from Satellite Measurements (Doctoral dissertation). Inst. für Meteorol. und Klimaforsch. Universität Karlsruhe (TH).
- De Luca, G., Silva, J.M.N., Cerasoli, S., Araújo, J., Campos, J., Di Fazio, S., Modica, G., 2019. Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo Toolbox. *Remote Sens.* 11, 1238. <https://doi.org/10.3390/rs11101238>
- Deilami, K., Kamruzzaman, M., Liu, Y., 2018. Urban heat island effect: A systematic review of spatio-temporal factors, data, methods, and mitigation measures. *Int. J. Appl. Earth Obs. Geoinf.* 67, 30–42. <https://doi.org/10.1016/j.jag.2017.12.009>
- Du, C., Ren, H., Qin, Q., Meng, J., Zhao, S., 2015. A practical split-window algorithm for estimating land surface temperature from landsat 8 data. *Remote Sens.* 7, 647–665. <https://doi.org/10.3390/rs70100647>
- Duan, S.B., Li, Z.L., Wang, C., Zhang, S., Tang, B.H., Leng, P., Gao, M.F., 2019. Land-surface temperature retrieval from Landsat 8 single-channel thermal infrared data in combination with NCEP reanalysis data and ASTER GED product. *Int. J. Remote Sens.* 40, 1763–1778. <https://doi.org/10.1080/01431161.2018.1460513>
- Dutta, D., Gupta, S., Chakraborty, A., 2022. Effect of different land use land cover on surface heat budget – A case study from a tropical humid region of India. *Remote Sens. Appl. Soc. Environ.* 25, 100675. <https://doi.org/10.1016/j.rsase.2021.100675>
- Dutta, D., Rahman, A., Paul, S.K., Kundu, A., 2021. Impervious surface growth and its inter-relationship with vegetation cover and land surface temperature in peri-urban areas of Delhi. *Urban Clim.* 37, 100799. <https://doi.org/10.1016/j.uclim.2021.100799>
- Eggimann, S., 2022. Expanding urban green space with superblocks. *Land use policy* 117, 106111. <https://doi.org/10.1016/j.landusepol.2022.106111>
- Elmes, A., Healy, M., Geron, N., Andrews, M.M., Rogan, J., Martin, D.G., Sangermano, F., Williams, C.A., Weil, B., 2020. Mapping spatiotemporal variability of the urban heat island across an urban gradient in Worcester, Massachusetts using in-situ Thermochrons and Landsat-8 Thermal Infrared

- Sensor (TIRS) data. *GIScience Remote Sens.* 57, 845–864.  
<https://doi.org/10.1080/15481603.2020.1818950>
- Emilsson, T., 2021. Urban life and climate change, in: Letcher, T.M. (Ed.), *The Impacts of Climate Change*. Elsevier, pp. 453–462.  
<https://doi.org/10.1016/b978-0-12-822373-4.00009-4>
- Fallmann, J., Emeis, S., 2020. How to bring urban and global climate studies together with urban planning and architecture? *Dev. Built Environ.* 4, 100023. <https://doi.org/10.1016/j.dibe.2020.100023>
- Febrita, Y., Ekasiwi, S.N.N., Antaryama, G.N.I., 2021. Urban River Landscape Factors Impact on Urban Microclimate in Tropical Region, in: *IOP Conference Series: Earth and Environmental Science*. p. 012032.  
<https://doi.org/10.1088/1755-1315/764/1/012032>
- Filho, W.L., Wolf, F., Castro-d, R., Li, C., Ojeh, V.N., Guti, N., Nagy, G.J., Savi, S., 2021. Addressing the Urban Heat Islands Effect: A Cross-Country Assessment of the Role of Green Infrastructure. *Sustainability* 13, 753.  
<https://doi.org/10.3390/su13020753>
- Firozjaei, M.K., Alavipanah, S.K., Liu, H., Sedighi, A., Mijani, N., Kiavarz, M., Weng, Q., 2019. A PCA – OLS Model for Assessing the Impact of Temperature Variations. *Remote Sens. Environ.* 11, 14–37.  
<https://doi.org/doi.org/10.3390/rs11182094>
- Firozjaei, M.K., Kiavarz, M., Alavipanah, S.K., Lakes, T., Qureshi, S., 2018. Monitoring and forecasting heat island intensity through multi-temporal image analysis and cellular automata-Markov chain modelling: A case of Babol city, Iran. *Ecol. Indic.* 91, 155–170.  
<https://doi.org/10.1016/j.ecolind.2018.03.052>
- Firozjaei, M.K., Weng, Q., Zhao, C., Kiavarz, M., Lu, L., Alavipanah, S.K., 2020. Surface anthropogenic heat islands in six megacities: An assessment based on a triple-source surface energy balance model. *Remote Sens. Environ.* 242, 111751. <https://doi.org/10.1016/j.rse.2020.111751>
- Fonseka, H.P.U., Zhang, H., Sun, Y., Su, H., Lin, H., Lin, Y., 2019. Urbanization and its impacts on land surface temperature in Colombo Metropolitan Area, Sri Lanka, from 1988 to 2016. *Remote Sens.* 11, 1–18.  
<https://doi.org/10.3390/rs11080926>

- Gaitani, N., Burud, I., Thiis, T., Santamouris, M., 2017. High-resolution spectral mapping of urban thermal properties with Unmanned Aerial Vehicles. *Build. Environ.* 121, 215–224. <https://doi.org/10.1016/j.buildenv.2017.05.027>
- Gaitani, N., Lehmann, C., Santamouris, M., Mihalakakou, G., Patargias, P., 2010. Using principal component and cluster analysis in the heating evaluation of the school building sector. *Appl. Energy* 87, 2079–2086. <https://doi.org/10.1016/j.apenergy.2009.12.007>
- Galanaki, E., Emmanouil, G., Lagouvardos, K., Kotroni, V., 2021. Long-term patterns and trends of shortwave global irradiance over the euro-mediterranean region. *Atmosphere (Basel)* 12, 1431. <https://doi.org/10.3390/atmos12111431>
- Galve, J.M., Coll, C., Caselles, V., Valor, E., Mira, M., 2008. Comparison of split-window and single-channel methods for land surface temperature retrieval from MODIS and aatsr data. *Int. Geosci. Remote Sens. Symp.* 3, 294–297. <https://doi.org/10.1109/IGARSS.2008.4779341>
- Gao, B.-C., 1996. NDWI - A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. *Remote Sens. Env.* 58, 257–266. <https://doi.org/10.3109/9781420073553-3>
- Gao, S., Zhan, Q., Yang, C., Liu, H., 2020. The diversified impacts of urban morphology on land surface temperature among urban functional zones. *Int. J. Environ. Res. Public Health* 17, 9578. <https://doi.org/10.3390/ijerph17249578>
- Gaur, S., Singh, R., 2023. A Comprehensive Review on Land Use/Land Cover (LULC) Change Modeling for Urban Development: Current Status and Future Prospects. *Sustainability* 15, 903. <https://doi.org/10.3390/su15020903>
- Gillespie, A., Rokugawa, S., Matsunaga, T., Steven Cothorn, J., Hook, S., Kahle, A.B., 1998. A temperature and emissivity separation algorithm for advanced spaceborne thermal emission and reflection radiometer (ASTER) images. *IEEE Trans. Geosci. Remote Sens.* 36, 1113–1126. <https://doi.org/10.1109/36.700995>
- Grilo, F., Pinho, P., Aleixo, C., Catita, C., Silva, P., Lopes, N., Freitas, C., Santos-Reis, M., McPhearson, T., Branquinho, C., 2020. Using green to cool the grey: Modelling the cooling effect of green spaces with a high spatial resolution.

Sci. Total Environ. 724, 138182.  
<https://doi.org/10.1016/j.scitotenv.2020.138182>

Guha, S., 2019. Analytical study of seasonal variability in land surface temperature with normalized difference vegetation index, normalized difference water index, normalized difference built-up index, and normalized multiband drought index. *J. Appl. Remote Sens.* 13, 024518. <https://doi.org/10.1117/1.jrs.13.024518>

Guha, S., Govil, H., Gill, N., Dey, A., 2021. A long-term seasonal analysis on the relationship between LST and NDBI using Landsat data. *Quat. Int.* 575–576, 249–258. <https://doi.org/10.1016/j.quaint.2020.06.041>

Guha, S., Govil, H., Taloor, A.K., Gill, N., Dey, A., 2022. Land surface temperature and spectral indices: A seasonal study of Raipur City. *Geod. Geodyn.* 13, 72–82. <https://doi.org/10.1016/j.geog.2021.05.002>

Guillevic, P., Göttsche, F., Nickeson, J., Hulley, G., Ghent, D., Yu, Y., Trigo, I., Hook, S., Sobrino, J.A., Remedios, J., Román, M., Camacho, F., 2018. Land Surface Temperature Product Validation Best Practice Protocol. Version 1.1. <https://doi.org/10.5067/doc/ceoswgcv/lpv/lst.001>

Gupta, N., Mathew, A., Khandelwal, S., 2019. Analysis of cooling effect of water bodies on land surface temperature in nearby region: A case study of Ahmedabad and Chandigarh cities in India. *Egypt. J. Remote Sens. Sp. Sci.* 22, 81–93. <https://doi.org/10.1016/j.ejrs.2018.03.007>

Hassan, T., Zhang, J., Prodhan, F.A., Pangali Sharma, T.P., Bashir, B., 2021. Surface urban heat islands dynamics in response to lulc and vegetation across south asia (2000–2019). *Remote Sens.* 13, 3177. <https://doi.org/10.3390/rs13163177>

Hayes, A.T., Jandaghian, Z., Lacasse, M.A., Gaur, A., Lu, H., Laouadi, A., Ge, H., Wang, L., 2022. Nature-Based Solutions (NBSs) to Mitigate Urban Heat Island (UHI) Effects in Canadian Cities. *Buildings* 12, 925. <https://doi.org/10.3390/buildings12070925>

Hellings, A., Rienow, A., 2021. Mapping land surface temperature developments in functional urban areas across europe. *Remote Sens.* 13, 2111. <https://doi.org/10.3390/rs13112111>

- Hook, S.J., Gabell, A.R., Green, A.A., Kealy, P.S., 1992. A comparison of techniques for extracting emissivity information from thermal infrared data for geologic studies. *Remote Sens. Environ.* 42, 123–135. [https://doi.org/10.1016/0034-4257\(92\)90096-3](https://doi.org/10.1016/0034-4257(92)90096-3)
- Hu, D., Meng, Q., Zhang, L., Zhang, Y., 2020. Spatial quantitative analysis of the potential driving factors of land surface temperature in different “Centers” of polycentric cities: A case study in Tianjin, China. *Sci. Total Environ.* 706, 135244. <https://doi.org/10.1016/j.scitotenv.2019.135244>
- Hu, L., Brunsell, N.A., 2015. A new perspective to assess the urban heat island through remotely sensed atmospheric profiles. *Remote Sens. Environ.* 158, 393–406. <https://doi.org/10.1016/j.rse.2014.10.022>
- Hu, L., Monaghan, A., Voogt, J.A., Barlage, M., 2016. A first satellite-based observational assessment of urban thermal anisotropy. *Remote Sens. Environ.* 181, 111–121. <https://doi.org/10.1016/j.rse.2016.03.043>
- Huang, C., Wylie, B., Yang, L., Homer, C., 2002. Derivation of a tasseled cap transformation based on Landsat 7 at-satellite reflectance. *Int. J. Remote Sens.* 23, 1741–1748.
- Huang, J.M., Chang, H.Y., Wang, Y.S., 2020. Spatiotemporal changes in the built environment characteristics and urban heat island effect in a medium-sized city, chiayi city, taiwan. *Sustainability* 12, 365. <https://doi.org/10.3390/su12010365>
- Huang, K., Li, X., Liu, X., Seto, K.C., 2019. Projecting global urban land expansion and heat island intensification through 2050. *Environ. Res. Lett.* 14, 114037. <https://doi.org/10.1088/1748-9326/ab4b71>
- Huang, X., Wang, Y., 2019. Investigating the effects of 3D urban morphology on the surface urban heat island effect in urban functional zones by using high-resolution remote sensing data: A case study of Wuhan, Central China. *ISPRS J. Photogramm. Remote Sens.* 152, 119–131. <https://doi.org/10.1016/j.isprsjprs.2019.04.010>
- Hulley, G., Nickeson, J., 2020. M\*D21 (MYD21/MOD21) and M\*D11 (MYD11/MYD21) Land Surface Temperature and Emissivity (LST&E) Products Status Report.

- Hulley, G.C., Hook, S.J., Abbott, E., Malakar, N., Islam, T., Abrams, M., 2015. The ASTER Global Emissivity Dataset (ASTER GED): Mapping Earth's emissivity at 100 meter spatial scale. *Geophys. Res. Lett.* 42, 7966–7976. <https://doi.org/10.1002/2015GL065564>
- IDEAM. Instituto de Hidrología Meteorología y Estudios Ambientales, 2017. Tercera comunicación nacional de Colombia a la Convención Marco de las Naciones Unidas sobre cambio climático (CMNUCC).
- International LST and Emissivity Working Group, 2018. Due globtemperature project. Product User Guide.
- IPCC, 2022. Climate Change 2022 - Mitigation of Climate Change, Intergovernmental Panel on Climate Change. Mitigation of Climate Change. Working Group III Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Geneva, Switzerland.
- IPCC, 2018. Global warming of 1.5°C An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change,.
- IPCC, 2013. Climate Change 2013: Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, Cambridge University Press. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA. <https://doi.org/10.1017/CBO9781107415324>
- Jensen, J.R., 2007. Remote Sensing of the Environment: An Earth Resource Perspective, Second. ed, Pearson Education Limited. Pearson Prentice Hall.
- Jiang, L., Zhang, L., Yu, L., Wang, D., 2019. Class-specific attribute weighted naive Bayes. *Pattern Recognit.* 88, 321–330. <https://doi.org/10.1016/j.patcog.2018.11.032>
- Jiménez-Muñoz, J.C., Cristobal, J., Sobrino, J.A., Sòria, G., Ninyerola, M., Pons, X., 2009. Revision of the single-channel algorithm for land surface temperature retrieval from landsat thermal-infrared data. *IEEE Trans. Geosci. Remote Sens.* 47, 339–349. <https://doi.org/10.1109/TGRS.2008.2007125>

- Jiménez-Munoz, J.C., Sobrino, J.A., 2003. A generalized single-channel method for retrieving land surface temperature from remote sensing data. *J. Geophys. Res. Atmos.* 108, 4688. <https://doi.org/10.1029/2003jd003480>
- Jiménez-Muñoz, J.C., Sobrino, J.A., Skokovi, D., Mattar, C., Cristóbal, J., Bands, A.L.-T., 2014. Land Surface Temperature Retrieval Methods From Landsat-8 Thermal Infrared Sensor Data. *IEEE Geosci. Remote Sens. Lett.* 11, 1840–1843.
- John, J., Chithra, N.R., Thampi, S.G., 2021. Assessment of land surface temperature dynamics over the Bharathapuzha River Basin, India. *Acta Geophys.* 69, 855–876. <https://doi.org/10.1007/s11600-021-00593-7>
- Käfer, P.S., Rocha, N.S., Diaz, L.R., Kaiser, E.A., Costa, S.T.L., Hallal, G., Veeck, G., Roberti, D., Rolim, S.B.A., 2020. Seasonal Assessment Of Surface Temperature With Normalized Vegetation Index And Surface Albedo Over Pampa Biome, in: *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*. pp. 471–476. <https://doi.org/10.5194/isprs-archives-XLII-3-W12-2020-471-2020>
- Kaiser, E.A., Rolim, S.B.A., Grondona, A.E.B., Hackmann, C.L., Linn, R. de M., Käfer, P.S., da Rocha, N.S., Diaz, L.R., 2022. Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images. *Atmosphere (Basel)*. 13, 460. <https://doi.org/10.3390/atmos13030460>
- Khalil, U., Aslam, B., Azam, U., Khalid, H.M.D., 2021. Time Series Analysis of Land Surface Temperature and Drivers of Urban Heat Island Effect Based on Remotely Sensed Data to Develop a Prediction Model. *Appl. Artif. Intell.* 1–26. <https://doi.org/10.1080/08839514.2021.1993633>
- Khan, M.S., Ullah, S., Chen, L., 2021. Comparison on land-use/land-cover indices in explaining land surface temperature variations in the city of beijing, china. *Land* 10, 1018. <https://doi.org/10.3390/land10101018>
- Kim, S.W., Brown, R.D., 2021. Urban heat island (UHI) intensity and magnitude estimations: A systematic literature review. *Sci. Total Environ.* 779, 146389. <https://doi.org/10.1016/j.scitotenv.2021.146389>
- Kong, J., Zhao, Y., Carmeliet, J., Lei, C., 2021. Urban heat island and its interaction with heatwaves: A review of studies on mesoscale. *Sustainability* 13, 10923.

<https://doi.org/10.3390/su131910923>

- Kumar, D., Shekhar, S., 2015. Statistical analysis of land surface temperature-vegetation indexes relationship through thermal remote sensing. *Ecotoxicol. Environ. Saf.* 121, 39–44. <https://doi.org/10.1016/j.ecoenv.2015.07.004>
- Lamqadem, A.A., Saber, H., Pradhan, B., 2018. Quantitative assessment of desertification in an arid oasis using remote sensing data and spectral index techniques. *Remote Sens.* 10, 1862. <https://doi.org/10.3390/rs10121862>
- Langsdale, M.F., Dowling, T.P.F., Wooster, M., Johnson, J., Grosvenor, M.J., de Jong, M.C., Johnson, W.R., Hook, S.J., Rivera, G., 2020. Inter-comparison of field-and laboratory-derived surface emissivities of natural and manmade materials in support of land surface temperature (Lst) remote sensing. *Remote Sens.* 12, 4127. <https://doi.org/10.3390/rs12244127>
- Larnicol, M., Launeau, P., Gernez, P., 2018. Using high-resolution airborne data to evaluate MERIS atmospheric correction and intra-pixel variability in nearshore turbid waters. *Remote Sens.* 10, 274. <https://doi.org/10.3390/rs10020274>
- Le, M.T., Tuan Le, H., Shukurov, I., Slesarev, M., 2020. Sulfur-extended asphalt concrete with assessing the surface temperature of roads affecting urban heat island. *IOP Conf. Ser. Mater. Sci. Eng.* 869, 022007. <https://doi.org/10.1088/1757-899X/869/2/022007>
- Lemus-Canovas, M., Martin-Vide, J., Moreno-Garcia, M.C., Lopez-Bustins, J.A., 2020. Estimating Barcelona's metropolitan daytime hot and cold poles using Landsat-8 Land Surface Temperature. *Sci. Total Environ.* 699. <https://doi.org/10.1016/j.scitotenv.2019.134307>
- Lezama Valdes, L.M., Katurji, M., Meyer, H., 2021. A machine learning based downscaling approach to produce high spatio-temporal resolution land surface temperature of the antarctic dry valleys from MODIS data. *Remote Sens.* 13, 4673. <https://doi.org/10.3390/rs13224673>
- Li, F., Jackson, T.J., Kustas, W.P., Schmugge, T.J., French, A.N., Cosh, M.H., Bindlish, R., 2004. Deriving land surface temperature from Landsat 5 and 7 during SMEX02/SMACEX. *Remote Sens. Environ.* 92, 521–534. <https://doi.org/10.1016/j.rse.2004.02.018>

- Li, H., Wang, H., Yang, Y., Du, Y., Cao, B., Bian, Z., Liu, Q., 2019. Evaluation of Atmospheric Correction Methods for the ASTER Temperature and Emissivity Separation Algorithm Using Ground Observation Networks in the HiWATER Experiment. *IEEE Trans. Geosci. Remote Sens.* 57, 1–14. <https://doi.org/10.1109/TGRS.2018.2879316>
- Li, K., Chen, Y., Gao, S., 2021. Comparative Analysis of Variations and Patterns between Surface Urban Heat Island Intensity and Frequency across 305 Chinese Cities. *Remote Sens.* 13, 3505.
- Li, L., Zha, Y., 2019. Satellite-based spatiotemporal trends of canopy urban heat islands and associated drivers in China's 32 major cities. *Remote Sens.* 11, 1–17. <https://doi.org/10.3390/rs11010102>
- Li, T., Meng, Q., 2018. A mixture emissivity analysis method for urban land surface temperature retrieval from Landsat 8 data. *Landsc. Urban Plan.* 179, 63–71. <https://doi.org/10.1016/j.landurbplan.2018.07.010>
- Li, X., Wang, R., Chen, X., Li, Y., Duan, Y., 2022. Classification of Transmission Line Corridor Tree Species Based on Drone Data and Machine Learning. *Sustainability* 14, 8273. <https://doi.org/10.3390/su14148273>
- Li, X., Zhou, W., 2019. Spatial patterns and driving factors of surface urban heat island intensity: A comparative study for two agriculture-dominated regions in China and the USA. *Sustain. Cities Soc.* 48, 101518. <https://doi.org/10.1016/j.scs.2019.101518>
- Li, Y., Sun, Y., Li, J., Gao, C., 2020. Socioeconomic drivers of urban heat island effect: Empirical evidence from major Chinese cities. *Sustain. Cities Soc.* 63, 102425. <https://doi.org/10.1016/j.scs.2020.102425>
- Li, Y., Zhao, Z., Xin, Y., Xu, A., Xie, S., Yan, Y., Wang, L., 2022. How Are Land-Use/Land-Cover Indices and Daytime and Nighttime Land Surface Temperatures Related in Eleven Urban Centres in Different Global Climatic Zones? *Land* 11, 1312.
- Li, Z.L., Tang, B.H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I.F., Sobrino, J.A., 2013a. Satellite-derived land surface temperature: Current status and perspectives. *Remote Sens. Environ.* 131, 14–37. <https://doi.org/10.1016/j.rse.2012.12.008>

- Li, Z.L., Wu, H., Wang, N., Qiu, S., Sobrino, J.A., Wan, Z., Tang, B.H., Yan, G., 2013b. Land surface emissivity retrieval from satellite data. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431161.2012.716540>
- Lillesand, T., Kieffer, R., Chipman, J., 2004. *Remote Sensing and Image Interpretation*, Fifth. ed, John Wiley & Sons. Wiley.
- Liu, C., Li, Y., 2018. Spatio-temporal features of urban heat island and its relationship with land use/cover in mountainous city: A case study in Chongqing. *Sustainability* 10, 1943. <https://doi.org/10.3390/su10061943>
- Liu, M., Ma, H., Bai, Y., 2021. Understanding the Drivers of Land Surface Temperature Based on Multisource Data: A Spatial Econometric Perspective. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 14, 12263–12272. <https://doi.org/10.1109/JSTARS.2021.3129842>
- Liu, S., Song, D., Yu, B., 2017. The Objective and Methodology of Urban Climate Map for the City of Xiamen. *Procedia Eng.* 180, 462–470. <https://doi.org/10.1016/j.proeng.2017.04.205>
- Liu, W., Meng, Q., Allam, M., Zhang, L., Hu, D., Menenti, M., 2021. Driving factors of land surface temperature in urban agglomerations: A case study in the pearl river delta, china. *Remote Sens.* 13, 2858. <https://doi.org/10.3390/rs13152858>
- Liu, X., Kim, R., Zhang, W., Guan, W.W., Subramanian, S. V., 2022. Spatial Variations of Village-Level Environmental Variables from Satellite Big Data and Implications for Public Health–Related Sustainable Development Goals. *Sustainability* 14, 10450. <https://doi.org/10.3390/su141610450>
- Lu, L., Weng, Q., Xiao, D., Guo, H., Li, Q., Hui, W., 2020. Spatiotemporal variation of surface urban heat islands in relation to land cover composition and configuration: A multi-scale case study of Xi'an, China. *Remote Sens.* 12, 2713. <https://doi.org/10.3390/RS12172713>
- Lu, Y., Wu, P., Xu, K., 2022. Multi-Time Scale Analysis of Urbanization in Urban Thermal Environment in Major Function-Oriented Zones at Landsat-Scale: A Case Study of Hefei City, China. *Land* 11, 711.
- Lu, Y., Yue, W., Huang, Y., 2021. Effects of Land Use on Land Surface Temperature : A Case Study of Wuhan, China. *Int. J. Environ. Res. Public*

Heal. 18, 9987.

- Luo, K., Li, B., Moiwo, J.P., 2018. Monitoring land-use/land-cover changes at a provincial large scale using an object-oriented technique and medium-resolution remote-sensing images. *Remote Sens.* 10, 2012. <https://doi.org/10.3390/rs10122012>
- Mao, K., Qin, Z., Shi, J., Gong, P., 2005. A practical split-window algorithm for retrieving land-surface temperature from MODIS data. *Int. J. Remote Sens.* 26, 3181–3204. <https://doi.org/10.1080/01431160500044713>
- Marcq, S., Delogu, E., Chapelier, M., Vidal, T.H.G., 2023. DirecTES : A Direct Method for Land and Sea Surface Temperature and Emissivity Separation for Thermal Infrared Sensors — Application to TRISHNA and ECOSTRESS. *Remote Sens.* 15, 517.
- Marković, M., Cheema, J., Teofilović, A., Čepić, S., Popović, Z., Tomićević-Dubljević, J., Pause, M., 2021. Monitoring of spatiotemporal change of green spaces in relation to the land surface temperature: A case study of belgrade, serbia. *Remote Sens.* <https://doi.org/10.3390/rs13193846>
- Martin-Vide, J., Sarricolea, P., Moreno-García, M.C., 2015. On the definition of urban heat island intensity: The “rural” reference. *Front. Earth Sci.* 3, 1–3. <https://doi.org/10.3389/feart.2015.00024>
- McCarty, D., Lee, J., Kim, H.W., 2021. Machine Learning Simulation of Land Cover Impact on Surface Urban Heat Island Surrounding Park Areas. *Sustainability* 13, 12678.
- McMillin, L.M., 1975. Estimation of sea surface temperatures from two infrared window measurements with different absorption. *J. Geophys. Res.* 80, 5113–5117. <https://doi.org/10.1029/jc080i036p05113>
- Meng, Q., Liu, W., Zhang, L., Allam, M., Bi, Y., Hu, X., Gao, J., Hu, D., Jancsó, T., 2022. Relationships between Land Surface Temperatures and Neighboring Environment in Highly Urbanized Areas: Seasonal and Scale Effects Analyses of Beijing, China. *Remote Sens.* 14, 4340. <https://doi.org/10.3390/rs14174340>
- Miles, V., Esau, I., 2017. Seasonal and spatial characteristics of Urban Heat Islands (UHIs) in northern West Siberian cities. *Remote Sens.* 9.

<https://doi.org/10.3390/rs9100989>

- Mills, G., 2014. Urban climatology: History, status and prospects. *Urban Clim.* 10, 479–489. <https://doi.org/10.1016/j.uclim.2014.06.004>
- Ministerio de Medio Ambiente, 2021. Plan Nacional de Adaptación al Cambio Climático [WWW Document]. Cambio Climático y Gestión del Riesgo. URL <https://www.minambiente.gov.co/cambio-climatico-y-gestion-del-riesgo/plan-nacional-de-adaptacion-al-cambio-climatico/>
- Mirchooli, F., Sadeghi, S.H., Khaledi Darvishan, A., 2020. Analyzing spatial variations of relationships between Land Surface Temperature and some remotely sensed indices in different land uses. *Remote Sens. Appl. Soc. Environ.* 19, 100359. <https://doi.org/10.1016/j.rsase.2020.100359>
- Mirzaei, P.A., 2015. Recent challenges in modeling of urban heat island. *Sustain. Cities Soc.* 19, 200–206. <https://doi.org/10.1016/j.scs.2015.04.001>
- Mirzaei, P.A., Haghghat, F., 2010. Approaches to study Urban Heat Island - Abilities and limitations. *Build. Environ.* 45, 2192–2201. <https://doi.org/10.1016/j.buildenv.2010.04.001>
- Misra, S., Li, H., 2020. Noninvasive fracture characterization based on the classification of sonic wave travel times, in: Publishing, G.P. (Ed.), *Machine Learning for Subsurface Characterization*. Elsevier, Cambridge, Massachusetts, pp. 243–287.
- Mohammad, P., Goswami, A., Bonafoni, S., 2019. The impact of the land cover dynamics on surface urban heat island variations in semi-arid cities: A case study in Ahmedabad City, India, using multi-sensor/source data. *Sensors* 19, 3701. <https://doi.org/10.3390/s19173701>
- Molina, I., Martinez, E., Morillo, C., Velasco, J., Jara, A., 2016. Assessment of data fusion algorithms for earth observation change detection processes. *Sensors* 16, 1621. <https://doi.org/10.3390/s16101621>
- Mountrakis, G., Im, J., Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* 66, 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Mueller, N., Rojas-Rueda, D., Khreis, H., Cirach, M., Andrés, D., Ballester, J.,

- Bartoll, X., Daher, C., Deluca, A., Echave, C., Milà, C., Márquez, S., Palou, J., Pérez, K., Tonne, C., Stevenson, M., Rueda, S., Nieuwenhuijsen, M., 2020. Changing the urban design of cities for health: The superblock model. *Environ. Int.* 134, 105132. <https://doi.org/10.1016/j.envint.2019.105132>
- Municipio de Cartago Valle del Cauca - Alcaldía de Cartago, 2013. POT vigente [WWW Document]. POT viegente. URL <https://www.cartago.gov.co/pot-vigente/> (accessed 1.15.18).
- Mushore, T., Odindi, J., Mutanga, O., 2022. “Cool” Roofs as a Heat-Mitigation Measure in Urban Heat Islands: A Comparative Analysis Using Sentinel 2 and Landsat Data. *Remote Sens.* 14, 4247. <https://doi.org/10.3390/rs14174247>
- Musial, J.P., Bojanowski, J.S., 2022. Comparison of the Novel Probabilistic Self-Optimizing Vectorized Earth Observation Retrieval Classifier with Common Machine Learning Algorithms. *Remote Sens.* 14, 378. <https://doi.org/10.3390/rs14020378>
- Nadizadeh Shorabeh, S., Hamzeh, S., Zanganeh Shahraki, S., Firozjaei, M.K., Jokar Arsanjani, J., 2020. Modelling the intensity of surface urban heat island and predicting the emerging patterns: Landsat multi-temporal images and Tehran as case study. *Int. J. Remote Sens.* 41, 7384–7410. <https://doi.org/10.1080/01431161.2020.1759841>
- NASA, 2023. Global Climate Change [WWW Document]. Natl. Adm. Sp. Aeronaut. How do We know Clim. Chang. is real? URL <https://climate.nasa.gov/evidence/> (accessed 2.15.23).
- NASA, 2008. NASA Global Climate Change and Global Warming: Vital Signs of the Planet. Jet Propulsion Laboratory / National Aeronautics and Space Administration [WWW Document]. *Glob. Clim. Chang. Evid.* URL <https://climate.nasa.gov/evidence/>
- National Weather Service, 2020. The Atmospheric Window [WWW Document]. *Natl. Ocean. Atmos. Adm.* URL <https://www.weather.gov/jetstream/absorb> (accessed 6.21.22).
- Ng, E., Ren, C., 2015. The urban climatic map: A methodology for sustainable urban planning. Routledge, London and New York. <https://doi.org/10.4324/9781315717616>

- Núñez-Peiró, M., Sánchez-Guevara Sánchez, C., Neila González, F.J., 2021. Hourly evolution of intra-urban temperature variability across the local climate zones. The case of Madrid. *Urban Clim.* 39, 100921. <https://doi.org/10.1016/j.uclim.2021.100921>
- Núñez Peiró, M., Sánchez-Guevara Sánchez, C., Neila González, F.J., 2019. Source area definition for local climate zones studies. A systematic review. *Build. Environ.* 148, 258–285. <https://doi.org/10.1016/j.buildenv.2018.10.050>
- Oke, T.R., 2006. Towards better scientific communication in urban climate. *Theor. Appl. Climatol.* 84, 179–190. <https://doi.org/10.1007/s00704-005-0153-0>
- Okwuashi, O., Ndehedehe, C.E., 2020. Deep support vector machine for hyperspectral image classification. *Pattern Recognit.* 103, 107298. <https://doi.org/10.1016/j.patcog.2020.107298>
- Oliveira, A., Lopes, A., Niza, S., Soares, A., 2022. An urban energy balance-guided machine learning approach for synthetic nocturnal surface Urban Heat Island prediction: A heatwave event in Naples. *Sci. Total Environ.* 805, 150130. <https://doi.org/10.1016/j.scitotenv.2021.150130>
- Onačillová, K., Gallay, M., Paluba, D., Péliová, A., Tokarčík, O., Laubertová, D., 2022. Combining Landsat 8 and Sentinel-2 Data in Google Earth Engine to Derive Higher Resolution Land Surface Temperature Maps in Urban Environment. *Remote Sens. Env.* 14, 4076. <https://doi.org/https://doi.org/10.3390/rs14164076>
- Ozawa-Meida, L., Ortiz-Moya, F., Painter, B., Hengesbaugh, M., Nakano, R., Yoshida, T., Zusman, E., Bhattacharyya, S., 2021. Integrating the sustainable development goals (SDGs) into urban climate plans in the uk and japan: A text analysis. *Climate* 9, 100. <https://doi.org/10.3390/cli9060100>
- Pal, S., Sharma, P., 2021. A Review of Machine Learning Applications in Land Surface Modeling. *Earth* 2, 174–190. <https://doi.org/10.3390/earth2010011>
- Parmentier, B., 2014. Characterization of Land Transitions Patterns from Multivariate Time Series Using Seasonal Trend Analysis and Principal Component Analysis. *Remote Sens.* 6, 12639–12665. <https://doi.org/10.3390/rs61212639>
- Peng, J., Dan, Y., Qiao, R., Liu, Y., Dong, J., Wu, J., 2021. How to quantify the

- cooling effect of urban parks? Linking maximum and accumulation perspectives. *Remote Sens. Environ.* 252, 112135. <https://doi.org/10.1016/j.rse.2020.112135>
- Peng, S., Piao, S., Ciais, P., Friedlingstein, P., Otle, C., Bréon, F.M., Nan, H., Zhou, L., Myneni, R.B., 2012. Surface urban heat island across 419 global big cities. *Environ. Sci. Technol.* 46, 696–703. <https://doi.org/10.1021/es2030438>
- Pérez-Planells, L., Niclòs, R., Puchades, J., Coll, C., Göttsche, F.M., Valiente, J.A., Valor, E., Galve, J.M., 2021. Validation of sentinel-3 slstr land surface temperature retrieved by the operational product and comparison with explicitly emissivity-dependent algorithms. *Remote Sens.* 13, 2228. <https://doi.org/10.3390/rs13112228>
- Peuquet, D.J., 1992. An algorithm for calculating minimum Euclidean distance between two geographic features. *Comput. Geosci.* 18, 989–1001. [https://doi.org/10.1016/0098-3004\(92\)90016-K](https://doi.org/10.1016/0098-3004(92)90016-K)
- Qiao, Z., Wu, C., Zhao, D., Xu, X., Yang, J., Feng, L., Sun, Z., Liu, L., 2019. Determining the boundary and probability of surface urban heat island footprint based on a logistic model. *Remote Sens.* 11, 1368. <https://doi.org/10.3390/rs11111368>
- Qin, Z., Karnieli, A., Berliner, P., 2001. A mono-window algorithm for retrieving land surface temperature from Landsat TM data and its application to the Israel-Egypt border region. *Int. J. Remote Sens.* 22, 3719–3746. <https://doi.org/10.1080/01431160010006971>
- Qu, S., Wang, L., Lin, A., Yu, D., Yuan, M., Li, C., 2020. Distinguishing the impacts of climate change and anthropogenic factors on vegetation dynamics in the Yangtze River Basin, China. *Ecol. Indic.* 108, 105724. <https://doi.org/10.1016/j.ecolind.2019.105724>
- Rahman, M.A., Armson, D., Ennos, A.R., 2015. A comparison of the growth and cooling effectiveness of five commonly planted urban tree species. *Urban Ecosyst.* 18, 371–389. <https://doi.org/10.1007/s11252-014-0407-7>
- Rahman, M.M., Althobiani, F., Shahid, S., Viridis, S.G.P., Kamruzzaman, M., Rahaman, H., Momin, M.A., Hossain, M.B., Ghandourah, E.I., 2022. GIS and Remote Sensing-Based Multi-Criteria Analysis for Delineation of Groundwater Potential Zones: A Case Study for Industrial Zones in

- Bangladesh. *Sustainability* 14, 6667. <https://doi.org/10.3390/su14116667>
- Ramírez-Aguilar, E.A., Lucas Souza, L.C., 2019. Urban form and population density: Influences on Urban Heat Island intensities in Bogotá, Colombia. *Urban Clim.* 29, 100497. <https://doi.org/10.1016/j.uclim.2019.100497>
- Ren, C., Ng, E.Y.Y., Katschner, L., 2011. Urban climatic map studies: A review. *Int. J. Climatol.* 31, 2213–2233. <https://doi.org/10.1002/joc.2237>
- Ren, H., Liu, R., Qin, Q., Fan, W., Yu, L., Du, C., 2017. Mapping finer-resolution land surface emissivity using Landsat images in China. *J. Geophys. Res.* 122, 6764–6781. <https://doi.org/10.1002/2017JD026910>
- Rodrigues de Almeida, C., Teodoro, A.C., Gonçalves, A., 2021. Study of the Urban Heat Island (UHI) Using Remote Sensing Data/Techniques: A Systematic Review. *Environments* 8, 105.
- Romero Rodríguez, L., Sánchez Ramos, J., Sánchez de la Flor, F.J., Álvarez Domínguez, S., 2020. Analyzing the urban heat Island: Comprehensive methodology for data gathering and optimal design of mobile transects. *Sustain. Cities Soc.* 55, 102027. <https://doi.org/10.1016/j.scs.2020.102027>
- Roncancio, D.N., 2015. Study of heat island phenomenon in Andean Colombian tropical city. Case of study: Manizales-Caldas Colombia. Master Environ. Dev. National University of Colombia.
- Sangines, E.D., 2013. Metodología de evaluación de la isla de calor urbana y su utilización para identificar problemáticas energéticas y de planificación urbana. Universidad de Zaragoza.
- Santamouris, M., 2014. On the energy impact of urban heat island and global warming on buildings. *Energy Build.* 82, 100–113. <https://doi.org/10.1016/j.enbuild.2014.07.022>
- Saradjian, M.R., Jouybari-Moghaddam, Y., 2019. Land Surface Emissivity and temperature retrieval from Landsat-8 satellite data using Support Vector Regression and weighted least squares approach. *Remote Sens. Lett.* 10, 439–448. <https://doi.org/10.1080/2150704X.2019.1569273>
- Schwarz, N., Lautenbach, S., Seppelt, R., 2011. Exploring indicators for quantifying surface urban heat islands of European cities with MODIS land

- surface temperatures. *Remote Sens. Environ.* 115, 3175–3186. <https://doi.org/10.1016/j.rse.2011.07.003>
- Seasholtz, R.G., Buggele, A.E., Reeder, M.F., 1997. Flow measurements based on Rayleigh scattering and Fabry-Perot interferometer. *Opt. Lasers Eng.* 27, 543–570. [https://doi.org/10.1016/S0143-8166\(96\)00063-2](https://doi.org/10.1016/S0143-8166(96)00063-2)
- Seebacher, D., Miller, M., Fuchs, J., Keim, D., 2019. Visual Analytics of Volunteered Geographic Information : Detection and Investigation of Urban Heat Islands. *IEEE Comput. Graph. Appl.* 39, 83–95.
- Shi, H., Xian, G., Auch, R., Gallo, K., Zhou, Q., 2021. Urban Heat Island and Its Regional Impacts Using Remotely Sensed Thermal Data—A Review of Recent Developments and Methodology. *Land* 10, 867. <https://doi.org/10.3390/land10080867>
- Shrestha, D.P., Saepuloh, A., van der Meer, F., 2019. Land cover classification in the tropics, solving the problem of cloud covered areas using topographic parameters. *Int. J. Appl. Earth Obs. Geoinf.* 77, 84–93. <https://doi.org/10.1016/j.jag.2018.12.010>
- Shu, L., Zhang, H., You, Y., Cui, Y., Chen, W., 2021. Towards fire prediction accuracy enhancements by leveraging an improved naïve bayes algorithm. *Symmetry (Basel)*. 13, 530. <https://doi.org/10.3390/sym13040530>
- Snyder, W.C., Wan, Z., Zhang, Y., Feng, Y.Z., 1998. Classification-based emissivity for land surface temperature measurement from space. *Int. J. Remote Sens.* 19, 2753–2774. <https://doi.org/10.1080/014311698214497>
- Sobrino, J., Irakulis, I., 2020. A methodology for comparing the surface urban heat Island in selected urban agglomerations around the world from Sentinel-3 SLSTR data. *Remote Sens.* 12, 2052. <https://doi.org/10.3390/RS12122052>
- Sobrino, J.A., Jiménez-Muñoz, J.C., 2005. Land surface temperature retrieval from thermal infrared data: An assessment in the context of the Surface Processes and Ecosystem Changes Through Response Analysis (SPECTRA) mission. *J. Geophys. Res. D Atmos.* 110, D16103. <https://doi.org/10.1029/2004JD005588>
- Sobrino, J.A., Jiménez-Muñoz, J.C., Sòria, G., Romaguera, M., Guanter, L., Moreno, J., Plaza, A., Martínez, P., 2008. Land surface emissivity retrieval

- from different VNIR and TIR sensors. *IEEE Trans. Geosci. Remote Sens.* 46, 316–327. <https://doi.org/10.1109/TGRS.2007.904834>
- Sobrino, J.A., Li, Z.L., Stoll, M.P., Becker, F., 1996. Multi-channel and multi-angle algorithms for estimating sea and land surface temperature with ATSR data. *Int. J. Remote Sens.* 17, 2089–2114. <https://doi.org/10.1080/01431169608948760>
- Sobrino, J.A., Oltra-Carrió, R., Jiménez-Muñoz, J.C., Julien, Y., Sòria, G., Franch, B., Mattar, C., 2012. Emissivity mapping over urban areas using a classification-based approach: Application to the Dual-use European Security IR Experiment (DESIREX). *Int. J. Appl. Earth Obs. Geoinf.* 18, 141–147. <https://doi.org/10.1016/j.jag.2012.01.022>
- Sobrino, J.A., Oltra-Carrió, R., Sòria, G., Jiménez-Muñoz, J.C., Franch, B., Hidalgo, V., Mattar, C., Julien, Y., Cuenca, J., Romaguera, M., Gómez, J.A., de Miguel, E., Bianchi, R., Paganini, M., 2013. Evaluation of the surface urban heat island effect in the city of Madrid by thermal remote sensing. *Int. J. Remote Sens.* 34, 3177–3192. <https://doi.org/10.1080/01431161.2012.716548>
- Sobrino, J.A., Raissouni, N., 2000. Toward remote sensing methods for land cover dynamic monitoring: Application to Morocco. *Int. J. Remote Sens.* 21, 353–366. <https://doi.org/10.1080/014311600210876>
- Song, J., Chen, W., Zhang, J., Huang, K., Hou, B., Prishchepov, A. V., 2020. Effects of building density on land surface temperature in China: Spatial patterns and determinants. *Landsc. Urban Plan.* 198, 103794. <https://doi.org/10.1016/j.landurbplan.2020.103794>
- Song, J., Wang, J., Xia, X., Lin, R., Wang, Y., Zhou, M., Fu, D., 2021. Characterization of urban heat islands using city lights: Insights from modis and viirs dnb observations. *Remote Sens.* 13, 3180. <https://doi.org/10.3390/rs13163180>
- Stewart, I.D., Oke, T.R., 2012. Local climate zones for urban temperature studies. *Bull. Am. Meteorol. Soc.* 93, 1879–1900. <https://doi.org/10.1175/BAMS-D-11-00019.1>
- Suh, M.H., Jeong, M., 2022. Development of Bus Routes Reorganization Support Software Using the Naïve Bayes Classification Method. *Sustainability* 14, 4400. <https://doi.org/10.3390/su14084400>

- Sun, C.Y., Kato, S., Gou, Z., 2019. Application of low-cost sensors for urban heat island assessment: A case study in Taiwan. *Sustainability* 11, 2759. <https://doi.org/10.3390/su11102759>
- Sun, Y., Gao, C., Li, J., Wang, R., Liu, J., 2019. Quantifying the Effects of Urban Form on Land Surface Temperature in Subtropical High-Density Urban Areas Using Machine Learning. *Remote Sens.* 11, 959.
- Szymanowski, M., Kryza, M., 2012. Local regression models for spatial interpolation of urban heat island-an example from Wrocław, SW Poland. *Theor. Appl. Climatol.* 108, 53–71. <https://doi.org/10.1007/s00704-011-0517-6>
- Taheri, M., Mohammadian, A., Ganji, F., Bigdeli, M., Nasser, M., 2022. Energy-Based Approaches in Estimating Actual Evapotranspiration Focusing on Land Surface Temperature: A Review of Methods, Concepts, and Challenges. *Energies* 15, 1264. <https://doi.org/10.3390/en15041264>
- Tan, K., Liao, Z., Du, P., Wu, L., 2017. Land surface temperature retrieval from Landsat 8 data and validation with geosensor network. *Front. Earth Sci.* 11, 20–34. <https://doi.org/10.1007/s11707-016-0570-7>
- Tang, B.H., Shao, K., Li, Z.L., Wu, H., Tang, R., 2015. An improved NDVI-based threshold method for estimating land surface emissivity using MODIS satellite data. *Int. J. Remote Sens.* 36, 4864–4878. <https://doi.org/10.1080/01431161.2015.1040132>
- Thanh Noi, P., Kappas, M., 2018. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors* 18, 18. <https://doi.org/10.3390/s18010018>
- Tomlinson, C.J., Chapman, L., Thornes, J.E., Baker, C., 2011. Remote sensing land surface temperature for meteorology and climatology: A review. *Meteorol. Appl.* 18, 296–306. <https://doi.org/10.1002/met.287>
- Tran, D.X., Pla, F., Latorre-Carmona, P., Myint, S.W., Caetano, M., Kieu, H. V., 2017. Characterizing the relationship between land use land cover change and land surface temperature. *ISPRS J. Photogramm. Remote Sens.* 124, 119–132. <https://doi.org/10.1016/j.isprsjprs.2017.01.001>
- Tucker, C.J., 1979. Red and photographic infrared linear combinations for

- monitoring vegetation. *Remote Sens. Environ.* 8, 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- U.S. Environmental Protection Agency, 2012. Cool Pavements. In: Reducing Urban Heat Islands: Compendium of Strategies [WWW Document]. <https://doi.org/10.2174/9781608054718113010008>
- U.S. Environmental Protection Agency, 2008. Reducing urban heat islands: Compendium of strategies. Draft [WWW Document]. <https://doi.org/10.1109/IICPE.2016.8079546>
- UN-Habitat, 2022. World City Report 2022. Envisaging the Future of Cities, United Nations Human Settlements Programme. Nairobi, Kenya.
- United Nations, 2019. World population prospects 2019: Highlights, Department of Economic and Social Affairs, Population Division. New York, USA.
- United Nations, 2018. The World's Cities in 2018—Data Booklet (ST/ESA/SER.A/417).
- United Nations, 2015. The 17 goals | Sustainable Development [WWW Document]. United Nations. URL <https://sdgs.un.org/goals> (accessed 7.27.22).
- United Nations, 2010. World urbanization prospects: the 2009 Revision, Department of Economic and Social Affairs. New York, USA.
- Valor, E., Caselles, V., 1996. Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. *Remote Sens. Environ.* 57, 167–184. [https://doi.org/10.1016/0034-4257\(96\)00039-9](https://doi.org/10.1016/0034-4257(96)00039-9)
- Van De Griend, A.A., Owe, M., 1993. On the relationship between thermal emissivity and the normalized difference vegetation index for natural surfaces. *Int. J. Remote Sens.* 14, 1119–1131. <https://doi.org/10.1080/01431169308904400>
- Vanhellemont, Q., 2020. Combined land surface emissivity and temperature estimation from Landsat 8 OLI and TIRS. *ISPRS J. Photogramm. Remote Sens.* 166, 390–402. <https://doi.org/10.1016/j.isprsjprs.2020.06.007>
- Vásquez-Álvarez, P.E., Flores-Vázquez, C., Cobos-Torres, J.C., Cobos-Mora, S.L.,

2022. Urban Heat Island Mitigation through Planned Simulation. *Sustainability* 14, 8612. <https://doi.org/10.3390/su14148612>
- Vilar, P., Morais, T.G., Rodrigues, N.R., Gama, I., Monteiro, M.L., Domingos, T., Teixeira, R.F.M., 2020. Object-based classification approaches for multitemporal identification and monitoring of pastures in agroforestry regions using multispectral unmanned aerial vehicle products. *Remote Sens.* 12, 814. <https://doi.org/10.3390/rs12050814>
- Villamil-Almeida, H.J., Blanco-Mantilla, K.A., Salah-García, O.Y., García-Sánchez, C.E., 2020. Characterization of the urban heat island at Bucaramanga, Colombia, using realtime temperature monitoring. *Rev. Fac. Ing. Univ. Antioquia* 10–21. <https://doi.org/10.17533/UDEA.REDIN.20191260>
- Vinod, H.D., 2022. Kernel Regression Coefficients for Practical Significance. *J. Risk Financ. Manag.* 15, 32. <https://doi.org/10.3390/jrfm15010032>
- Vlassova, L., 2016. Land Surface Temperature (LST) estimated from Landsat images: applications in burnt areas and tree-grass woodlands (dehesas) (Doctoral dissertation). Dep. Geografía y Ord. del Territ. Universidad de Zaragoza.
- Vlassova, L., Perez-Cabello, F., Nieto, H., Martín, P., Riaño, D., Riva, J.D. La, 2014. Assessment of methods for land surface temperature retrieval from landsat-5 TM images applicable to multiscale tree-grass ecosystem modeling. *Remote Sens.* 6, 4345–4368. <https://doi.org/10.3390/rs6054345>
- Voogt, J.A., Oke, T.R., 2003. Thermal remote sensing of urban climates. *Remote Sens. Environ.* 86, 370–384. [https://doi.org/10.1016/S0034-4257\(03\)00079-8](https://doi.org/10.1016/S0034-4257(03)00079-8)
- Vujovic, S., Haddad, B., Karaky, H., Sebaibi, N., Boutouil, M., 2021. Urban Heat Island: Causes , Consequences , and Mitigation Measures with Emphasis on Reflective and Permeable Pavements. *CivilEng* 2, 459–484.
- Wang, D., Ma, R., Xue, K., Loiselle, S.A., 2019. The assessment of landsat-8 OLI atmospheric correction algorithms for inland waters. *Remote Sens.* 11, 169. <https://doi.org/10.3390/rs11020169>
- Wang, H., Mao, K., Mu, F., Shi, J., Yang, J., Li, Z., Qin, Z., 2019. A split window algorithm for retrieving land surface temperature from FY-3D MERSI-2 data.

- Remote Sens. 11, 2083. <https://doi.org/10.3390/rs11182083>
- Wang, H., Zhang, Y., Tsou, J.Y., Li, Y., 2017. Surface urban heat island analysis of shanghai (China) based on the change of land use and land cover. Sustainability 9, 1538. <https://doi.org/10.3390/su9091538>
- Wang, J., Huang, B., Fu, D., Atkinson, P.M., 2015. Spatiotemporal variation in surface urban heat island intensity and associated Determinants across major Chinese cities. Remote Sens. 7, 3670–3689. <https://doi.org/10.3390/rs70403670>
- Wang, M., Wan, Y., Ye, Z., Lai, X., 2017. Remote sensing image classification based on the optimal support vector machine and modified binary coded ant colony optimization algorithm. Inf. Sci. (Ny). 402, 50–68. <https://doi.org/10.1016/j.ins.2017.03.027>
- Wang, M., Zhang, Z., He, G., Wang, G., Long, T., Peng, Y., 2016. An enhanced single-channel algorithm for retrieving land surface temperature from Landsat series data. J. Geophys. Res. Atmos. 121, 11712–11722. <https://doi.org/10.1038/175238c0>
- Wang, Q., Blackburn, G.A., Onojeghuo, A.O., Dash, J., Zhou, L., Zhang, Y., Atkinson, P.M., 2017. Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. IEEE Trans. Geosci. Remote Sens. 55, 3885–3899. <https://doi.org/10.1109/TGRS.2017.2683444>
- Wang, Q., Wang, X., Zhou, Y., Liu, D., Wang, H., 2022. The dominant factors and influence of urban characteristics on land surface temperature using random forest algorithm. Sustain. Cities Soc. 79, 103722. <https://doi.org/10.1016/j.scs.2022.103722>
- Wang, S., He, L., 2014. Practical split-window algorithm for retrieving land surface temperature over agricultural areas from ASTER data. J. Appl. Remote Sens. 8, 083582-1-083582–17. <https://doi.org/10.1117/1>
- Wang, Z., Meng, Q., Allam, M., Hu, D., Zhang, L., Menenti, M., 2021. Environmental and anthropogenic drivers of surface urban heat island intensity: A case-study in the Yangtze River Delta, China. Ecol. Indic. 128, 107845. <https://doi.org/10.1016/j.ecolind.2021.107845>
- Wang, Z., Sun, D., Hu, C., Wang, Y., Zhang, J., 2022. Seasonal Contrast and

- Interactive Effects of Potential Drivers on Land Surface Temperature in the Sichuan Basin, China. *Remote Sens.* 14, 1292. <https://doi.org/10.3390/rs14051292>
- Ward, K., Lauf, S., Kleinschmit, B., Endlicher, W., 2016. Heat waves and urban heat islands in Europe: A review of relevant drivers. *Sci. Total Environ.* 569–570, 527–539. <https://doi.org/10.1016/j.scitotenv.2016.06.119>
- Wasif Ali, N. ul A.B., Amir, S., Iqbal, K.M.J., Shah, A.A., Saqib, Z., Akhtar, N., Ullah, W., Tariq, M.A.U.R., 2022. Analysis of Land Surface Temperature Dynamics in Islamabad by Using MODIS Remote Sensing Data. *Sustain.* 14. <https://doi.org/10.3390/su14169894>
- Wei, Y., Wang, W., Tang, X., Li, H., Hu, H., Wang, X., 2022. Classification of Alpine Grasslands in Cold and High Altitudes Based on Multispectral Landsat-8 Images : A Case Study in Sanjiangyuan National Park , China. *Remote Sens.* 14, 3714.
- Weiss, M., Baret, F., 2016. S2ToolBox Level 2 products: LAI, FAPAR, FCOVER.
- Weng, Q., 2009. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. *ISPRS J. Photogramm. Remote Sens.* 64, 335–344. <https://doi.org/10.1016/j.isprsjprs.2009.03.007>
- Weng, Q., Firozjaei, M.K., Sedighi, A., Kiavarz, M., Alavipanah, S.K., 2019. Statistical analysis of surface urban heat island intensity variations: A case study of Babol city, Iran. *GIScience Remote Sens.* 56, 576–604. <https://doi.org/10.1080/15481603.2018.1548080>
- Wilks, D.S., 2019. *Statistical Methods in the Atmospheric Sciences*, Fourth ed. ed. Elsevier.
- Wu, H., Li, Z.L., 2009. Scale issues in remote sensing: A review on analysis, processing and modeling. *Sensors* 9, 1768–1793. <https://doi.org/10.3390/s90301768>
- Wu, X., Zhang, L., Zang, S., 2019. Examining seasonal effect of urban heat island in a coastal city. *PLoS One* 14, e0217850. <https://doi.org/10.1371/journal.pone.0217850>

- Wu, Z., Ren, Y., 2019. A bibliometric review of past trends and future prospects in urban heat island research from 1990 to 2017. *Environ. Rev.* 27, 241–251. <https://doi.org/10.1139/er-2018-0029>
- Wujeska-Klaue, A., Pfautsch, S., 2020. The best Urban trees for daytime cooling leave nights slightly warmer. *Forests* 11, 945. <https://doi.org/10.3390/f11090945>
- Xiang, Y., Huang, C., Huang, X., Zhou, Z., Wang, X., 2021. Seasonal variations of the dominant factors for spatial heterogeneity and time inconsistency of land surface temperature in an urban agglomeration of central China. *Sustain. Cities Soc.* 75, 103285. <https://doi.org/10.1016/j.scs.2021.103285>
- Yang, C., Yan, F., Zhang, S., 2020. Comparison of land surface and air temperatures for quantifying summer and winter urban heat island in a snow climate city. *J. Environ. Manage.* 265, 110563. <https://doi.org/10.1016/j.jenvman.2020.110563>
- Yang, J., Tham, K.W., Lee, S.E., Santamouris, M., Sekhar, C., Kok, D., Cheong, W., 2017. Anthropogenic heat reduction through retrofitting strategies of campus buildings. *Energy Build.* 152, 813–822. <https://doi.org/10.1016/j.enbuild.2016.11.051>
- Yang, Q., Huang, X., Tang, Q., 2019. The footprint of urban heat island effect in 302 Chinese cities: Temporal trends and associated factors. *Sci. Total Environ.* 655, 652–662. <https://doi.org/10.1016/j.scitotenv.2018.11.171>
- Yao, L., Sun, S., Song, C., Li, J., Xu, W., Xu, Y., 2021. Understanding the spatiotemporal pattern of the urban heat island footprint in the context of urbanization, a case study in Beijing, China. *Appl. Geogr.* 133, 102496. <https://doi.org/10.1016/j.apgeog.2021.102496>
- Ye, X., Ren, H., Zhu, J., Fan, W., Qin, Q., 2022. Split-window Algorithm for Land Surface Temperature Retrieval from Landsat-9 Remote Sensing Images. *IEEE Geosci. Remote Sens. Lett.* 19, 7507205. <https://doi.org/10.1109/lgrs.2022.3184980>
- Yokoyama, H., Ooka, R., Kikumoto, H., 2018. Study of mobile measurements for detailed temperature distribution in a high-density urban area in Tokyo. *Urban Clim.* 24, 517–528. <https://doi.org/10.1016/j.uclim.2017.06.006>

- Yu, W., Ma, M., Li, Z., Tan, J., Wu, A., 2017. New scheme for validating remote-sensing land surface temperature products with station observations. *Remote Sens.* 9, 1210. <https://doi.org/10.3390/rs9121210>
- Yu, X., Guo, X., 2021. Extracting Fractional Vegetation Cover from Digital Photographs: A Comparison of In Situ, SamplePoint, and Image Classification Methods. *Sensors* 21, 7310.
- Yu, X., Liu, Y., Zhang, Z., Xiao, R., 2021. Influences of buildings on urban heat island based on 3D landscape metrics: an investigation of China's 30 megacities at micro grid-cell scale and macro city scale. *Landsc. Ecol.* 36, 2743–2762. <https://doi.org/10.1007/s10980-021-01275-x>
- Yu, Y., Shang, G., Duan, S., Yu, W., Labeled, J., Li, Z., 2022. Quantifying the Influences of Driving Factors on Land Surface Temperature during 2003–2018 in China Using Convergent Cross Mapping Method. *Remote Sens.* 14, 3280. <https://doi.org/10.3390/rs14143280>
- Zaitunah, A., Samsuri, S., Silitonga, A.F., Syaufina, L., 2022. Urban Greening Effect on Land Surface Temperature. *Sensors* 22, 4168. <https://doi.org/10.3390/s22114168>
- Zanchetta, A., Bitelli, G., Karnieli, A., 2016. Monitoring desertification by remote sensing using the Tasselled Cap transform for long-term change detection. *Nat. Hazards* 83, 223–237. <https://doi.org/10.1007/s11069-016-2342-9>
- Zeng, F.F., Feng, J., Zhang, Y., Tsou, J.Y., Xue, T., Li, Y., Li, R.Y.M., 2021. Comparative study of factors contributing to land surface temperature in high-density built environments in megacities using satellite imagery. *Sustainability* 13, 13706. <https://doi.org/10.3390/su132413706>
- Zha, Y., Gao, J., Ni, S., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *Int. J. Remote Sens.* 24, 583–594. <https://doi.org/10.1080/01431160304987>
- Zhang, H., Jiang, L., Yu, L., 2021. Attribute and instance weighted naive Bayes. *Pattern Recognit.* 111, 107674. <https://doi.org/10.1016/j.patcog.2020.107674>
- Zhang, H., Jiang, L., Yu, L., 2020. Class-specific attribute value weighting for Naive Bayes. *Inf. Sci. (Ny)*. 508, 260–274. <https://doi.org/10.1016/j.ins.2019.08.071>

- Zhao, X., Zhang, Y., Xie, S., Qin, Q., Wu, S., Luo, B., 2020. Outlier detection based on residual histogram preference for geometric multi-model fitting. *Sensors* 20, 3037. <https://doi.org/10.3390/s20113037>
- Zhao, Y., Wu, Q., Wei, P., Zhao, H., Zhang, X., Pang, C., 2022. Explore the Mitigation Mechanism of Urban Thermal Environment by Integrating Geographic Detector and Standard Deviation Ellipse (SDE). *Remote Sens.* 14, 3411.
- Zhi, Y., Shan, L., Ke, L., Yang, R., 2020. Analysis of Land Surface Temperature Driving Factors and Spatial Heterogeneity Research Based on Geographically Weighted Regression Model. *Complexity* 2020, 1–9. <https://doi.org/10.1155/2020/2862917>
- Zhou, D., Xiao, J., Bonafoni, S., Berger, C., Deilami, K., Zhou, Y., Frohking, S., Yao, R., Qiao, Z., Sobrino, J.A., 2019a. Satellite remote sensing of surface urban heat islands: Progress, challenges, and perspectives. *Remote Sens.* 11. <https://doi.org/10.3390/rs11010048>
- Zhou, D., Xiao, J., Bonafoni, S., Berger, C., Deilami, K., Zhou, Y., Frohking, S., Yao, R., Qiao, Z., Sobrino, J.A., 2019b. Satellite remote sensing of surface urban heat islands: Progress, challenges, and perspectives. *Remote Sens.* 11, 48. <https://doi.org/10.3390/rs11010048>
- Zumwald, M., Knüsel, B., Bresch, D.N., Knutti, R., 2021. Mapping urban temperature using crowd-sensing data and machine learning. *Urban Clim.* 35, 100739. <https://doi.org/10.1016/j.uclim.2020.100739>

# APÉNDICES.

## Apéndice A. Listado de imágenes satelitales procesadas

Tabla A1. Identificación de las escenas L5, L7, L8, S2 empleadas en este estudio

Sensor	ID escena	Fecha de adquisición	Hora UTM
Landsat 5 TM	LT50090572001036XXX01	2001.02.05	14:59
Landsat 7 ETM	LE70090572001188EDC00	2001.07.07	15:08
Landsat 7 ETM	LE70090572001284EDC00	2001.10.11	15:07
Landsat 7 ETM	LE70090572002127EDC00	2002.05.07	15:07
Landsat 7 ETM	LE70090572002207EDC00	2002.07.26	15:07
Landsat 7 ETM	LE70090572002335AGS02	2002.12.01	15:07
Landsat 7 ETM	LE70090572003002EDC00	2003.01.02	15:07
Landsat 7 ETM	LE70090572003066EDC00	2003.03.07	15:07
Landsat 7 ETM	LE70090572004229ASN01	2004.08.16	15:07
Landsat 7 ETM	LE70090572005071ASN00	2005.03.12	15:08
Landsat 7 ETM	LE70090572005167ASN00	2005.06.16	15:08
Landsat 7 ETM	LE70090572006218ASN00	2006.08.06	15:08
Landsat 7 ETM	LE70090572006266ASN00	2006.09.23	15:08
Landsat 7 ETM	LE70090572007365EDC00	2007.12.31	15:09
Landsat 7 ETM	LE70090572008096EDC00	2008.04.05	15:09
Landsat 7 ETM	LE70090572008256EDC00	2008.09.12	15:08
Landsat 5 TM	LT50090572009330CHM00	2009.11.26	15:09
Landsat 7 ETM	LE70090572010005EDC00	2010.01.05	15:10
Landsat 7 ETM	LE70090572010021EDC00	2010.01.21	15:11
Landsat 7 ETM	LE70090572011072EDC00	2011.03.13	15:12
Landsat 7 ETM	LE70090572011296ASN00	2011.10.23	15:12
Landsat 7 ETM	LE70090572012203ASN00	2012.07.21	15:14
Landsat 8 OLI/TIRS	LC80090572013197LGN01	2013.07.16	15:21
Landsat 8 OLI/TIRS	LC80090572014184LGN01	2014.07.03	15:19
Landsat 8 OLI/TIRS	LC80090572014200LGN01	2014.07.19	15:19

<b>Sensor</b>	<b>ID escena</b>	<b>Fecha de adquisición</b>	<b>Hora UTM</b>
Landsat 8 OLI/TIRS	LC80090572015091LGN01	2015.04.01	15:18
Landsat 8 OLI/TIRS	LC80090572015363LGN01	2015.12.29	15:19
Landsat 8 OLI/TIRS	LC80090572016190LGN01	2016.07.08	15:19
Landsat 8 OLI/TIRS	LC80090572016302LGN01	2016.10.28	15:19
Landsat 8 OLI/TIRS	LC80090572017112LGN00	2017.04.22	15:18
Landsat 8 OLI/TIRS	LC80090572017208LGN00	2017.07.27	15:19
Landsat 8 OLI/TIRS	LC80090572018099LGN00	2018.04.09	15:18
Landsat 8 OLI/TIRS	LC80090572018243LGN00	2018.08.31	15:18
Landsat 8 OLI/TIRS	LC80090572019022LGN00	2019.01.22	15:19
Landsat 8 OLI/TIRS	LC80090572019246LGN00	2019.09.03	15:19
Landsat 8 OLI/TIRS	LC80090572020009LGN00	2020.01.09	15:19
Landsat 8 OLI/TIRS	LC80090572020041LGN00	2020.02.10	15:19
Sentinel-2A	S2A_MSIL1C_20151231T153112_N0201_ R025_T18NVL_20151231T153112	2015.12.31	15:31
Sentinel-2A	S2A_MSIL1C_20160728T152642_N0204_ R025_T18NUL_20160728T153016	2016.07.28	15:27
Sentinel-2A	S2A_MSIL1C_20161016T152632_N0204_ _R025_T18NUL_20161016T152634	2016.10.16	15:27
Sentinel-2A	S2A_MSIL1C_20170404T153111_N0204_ R025_T18NUL_20170404T153109	2017.04.04	15:31
Sentinel-2A	S2A_MSIL1C_20170713T153111_N0205_ R025_T18NUL_20170713T153113	2017.07.13	15:31
Sentinel-2A	S2A_MSIL1C_20180409T152641_N0206_ R025_T18NUL_20180409T215706	2018.04.09	15:27
Sentinel-2A	S2A_MSIL1C_20180906T152641_N0206_ R025_T18NUL_20180906T190220	2018.09.06	15:27

<b>Sensor</b>	<b>ID escena</b>	<b>Fecha de adquisición</b>	<b>Hora UTM</b>
Sentinel-2A	S2A_MSIL2A_20190104T152631_N0211_R025_T18NUL_20190104T192952	2019.01.04	15:27
Sentinel-2A	S2A_MSIL2A_20190911T152641_N0213_R025_T18NUL_20190911T211055	2019.09.11	15:27
Sentinel-2A	S2A_MSIL2A_20200109T152631_N0213_R025_T18NUL_20200109T193810	2020.01.09	15:27
Sentinel-2A	S2A_MSIL2A_20200218T152631_N0214_R025_T18NUL_20200218T193733	2020.02.18	15:27

# Apéndice B. Procedimiento de verificación y ajuste de termómetros

Para realizar la verificación y ajuste de un termómetro T<sub>1</sub> es necesario contar con el certificado de calibración del termómetro que se usó como patrón, y realizar el proceso descrito a continuación.

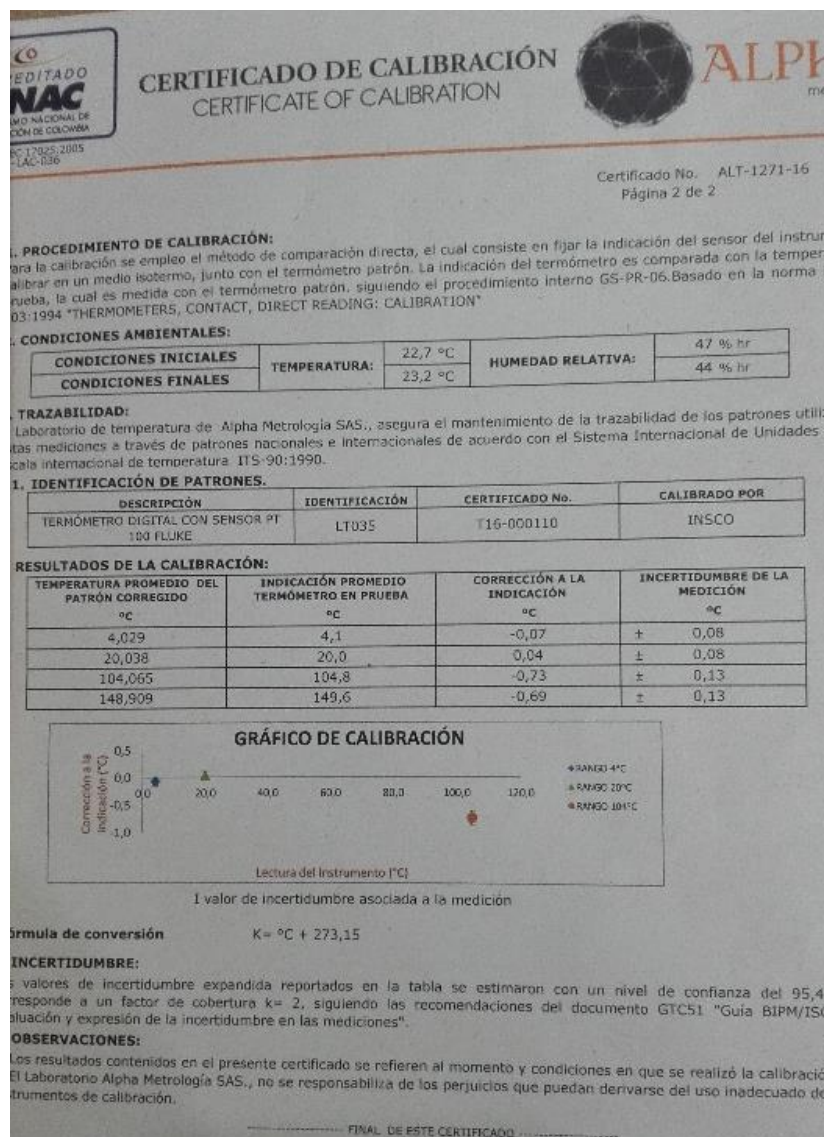


Figura B1. Certificado de calibración termómetro patrón

**PROCESO 1:** Con los valores de los resultados de calibración del termómetro patrón —provenientes del certificado de calibración— se obtuvo su ecuación de ajuste, así:

Tabla B1. Contraste mediciones T. patrón contra T. prueba

Termómetro patrón °C	Termómetro en prueba °C
4,029	4,1
20,038	20,0
104,065	104,8
148,909	149,6




Figura B2. Modelo de ajuste termómetro patrón

Aplicando la ecuación de regresión a los valores medidos del termómetro en prueba se obtuvieron los siguientes valores ajustados (lectura corregida):

Tabla B2. Lecturas corregidas del termómetro en prueba

Termómetro patrón °C	Termómetro en prueba °C	Lectura corregida
4,029	4,1	4,1
20,038	20,0	20,1
104,065	104,8	105,4
148,909	149,6	150,4

**PROCESO 2:** Ahora, para verificar y ajustar los valores registrados por el termómetro en prueba, se realizaron 5 observaciones a 3 temperaturas diferentes, 20, 30 y 40 °C.

Tabla B3. Modelo de ajuste para T=20 °C empleando 5 observaciones

	obs.1	obs.2	obs.3	obs.4	obs.5
Lectura termómetro patrón	Y <sub>1</sub>	Y <sub>2</sub>	Y <sub>3</sub>	Y <sub>4</sub>	Y <sub>5</sub>
y=1,0055x-0,0141 (resultado proceso 1)					
Lectura corregida termómetro patrón	Y <sub>1_corregida</sub>	Y <sub>2_corregida</sub>	Y <sub>3_corregida</sub>	Y <sub>4_corregida</sub>	Y <sub>5_corregida</sub>
Lectura termómetro en prueba	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>
Ecuación de regresión					
Lectura corregida termómetro en prueba	X <sub>1_corregida</sub>	X <sub>2_corregida</sub>	X <sub>3_corregida</sub>	X <sub>4_corregida</sub>	X <sub>5_corregida</sub>

La **lectura corregida del termómetro patrón** se ajustó empleando la ecuación de regresión por cada observación proveniente del proceso 1. Luego, La **lectura corregida del termómetro en prueba** se calibró empleando la **ecuación de regresión** obtenida al contrastar los valores de **lectura del termómetro en prueba** (eje x), contra los valores de la lectura **corregida del termómetro patrón** (eje y). El mismo procedimiento se aplicó a temperaturas de 30 y 40 °C.



Figura B3. Contraste lecturas T.prototipo contra T.patrón

## Apéndice C. Código fuente regresión lineal múltiple

```
# Carga de librerías -----  
  
library(openxlsx)  
library(ggplot2)  
library(raster)  
library(car) # Prueba Durbin Watson  
library(GGally) # gráfica correlaciones e histogramas  
library(psych)  
library(normtest)  
library(nortest)  
library(dplyr)  
library(gridExtra)  
  
# Carga de datos -----  
  
setwd ("D:/UPM/MLR/RStudio")  
datos <- read_excel("datos.xlsx")  
datos <- as.data.frame(datos)  
boxplot(datos) # vista previa de distribución de datos
```




Figura B4. Comportamiento general de los factores estudiados

```
# Extracción de muestras en posiciones específicas -----  
  
muestreo <- seq.int(from=1, to=18975, by=7)  
df <- datos[c(muestreo), ] # re-muestrea cada 7 registros de 'datos'  
#df <- datos[-c(muestreo), ] re-muestrea al inverso  
  
boxplot(df) # sacar en este punto a Excel para graficar agrupado  
write.xlsx(df, 'df.xlsx')
```




Figura B5. Comportamiento de los datos remuestreados

```
# Limpieza atípicos -----  
  
boxplot(df$TCW, plot=TRUE)$out  
atipicos <- boxplot(df$TCW, plot=FALSE)$out  
df <- df[-which(df$TCW %in% atipicos), ]  
boxplot(df)
```




Figura B6. Comportamiento de datos con eliminación de atípicos

# Modelo de regresión -----

**cor.test**(df\$NDVI, df\$TCG) # *verif.correlación, parecen explicar lo mismo*

```
##Pearson's product-moment correlation
##data: df$NDVI and df$TCG
##t = -251.61, df = 2699, p-value < 2.2e-16
##alternative hypothesis: true correlation is not equal to 0
##95 percent confidence interval:
## -0.9808294 -0.9777409
```

df\$TCG = NULL # *excluido previamente por alta correlación con NDVI*

df\$TCB = NULL # *excluido previamente por alta cantidad de atípicos*

df\$TCW = NULL # *excluido previamente por alta cantidad de atípicos*

modelo <- **lm**(LST ~ NDBI + NDVI + NDWI + PUC + PW, data = df)

**summary** (modelo)

```
##Residuals:
##   Min       1Q   Median       3Q      Max
##-1.68295 -0.25350 -0.01953  0.24054  2.19902

##Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
##(Intercept)  0.301057   0.014947  34.793 < 2e-16 ***
##NDBI         0.480637   0.054208   9.923 0.000333 ***
##NDVI         0.214922   0.022554  13.216 3.15e-05 ***
##NDWI        -0.619134   0.035398 -23.664 < 2e-16 ***
##PUC         -0.517881   0.014740 -39.618 < 2e-16 ***
##PW          -0.002316   0.032229  -0.072 0.942720
```

*# Selección de los mejores predictores -----*

```
step(object = modelo, direction = "both", trace = 1)
```

```
##Start:  AIC=-5120.69
##LST ~ NDBI + NDVI + NDWI + PUC + PW
##      Df Sum of Sq  RSS    AIC
##- PW   1     0.001 403.87 -5122.7
##<none>          403.87 -5120.7
##- NDBI  1     1.934 405.80 -5109.8
##- NDVI  1     2.605 406.47 -5105.3
##- NDWI  1    13.476 417.34 -5034.0
##- PUC   1    35.393 439.26 -4895.8
##
```

```

##Step:  AIC=-5122.68
##LST ~ NDBI + NDVI + NDWI + PUC
##
##      Df Sum of Sq  RSS    AIC
##<none>          403.87 -5122.7
##+ PW      1      0.001 403.87 -5120.7
##- NDBI    1      1.934 405.80 -5111.8
##- NDVI    1      2.612 406.48 -5107.3
##- NDWI    1     13.488 417.36 -5036.0
##- PUC     1     35.655 439.52 -4896.2
##
##Call:
##lm(formula = LST ~ NDBI + NDVI + NDWI + PUC, data = df)
##
##Coefficients:
##(Intercept)      NDBI      NDVI      NDWI      PUC
##    0.2996    0.4803    0.2150   -0.6192   -0.5137

```

```

modelo_def <- (lm(formula = LST ~ NDBI+NDVI+NDWI+PUC, data = df))
summary(modelo_def)

```

```

##Residuals:
##      Min       1Q   Median       3Q      Max
##-1.68354 -0.25293 -0.02034  0.24015  2.19931
##
##Coefficients:
##      Estimate Std. Error t value Pr(>|t|)
##(Intercept)  0.29959   0.01192  37.794 < 2e-16 ***
##NDBI         0.48033   0.05411   9.923 0.000333 ***
##NDVI         0.21404   0.02252  13.214 3.06e-05 ***
##NDWI        -0.61925   0.03137 -23.662 < 2e-16 ***
##PUC         -0.51366   0.01459 -39.612 < 2e-16 ***
##---

```

```
# Intervalos de confianza de los coeficientes del modelo -----
```

```
confint(modelo_def)
```

##	2.5 %	97.5 %
## (Intercept)	0.25660100	0.3425820
##NDBI	0.20911896	0.7115321
##NDVI	0.08753525	0.2425199
"-----"	0.55500000	0.55500000

```
# Gráfica de correlaciones -----
```

```
df$PW = NULL # excluida por el modelo de regresión
```

```
pairs.panels(x = df, ellipses = FALSE, lm = TRUE, method = "pearson")
```

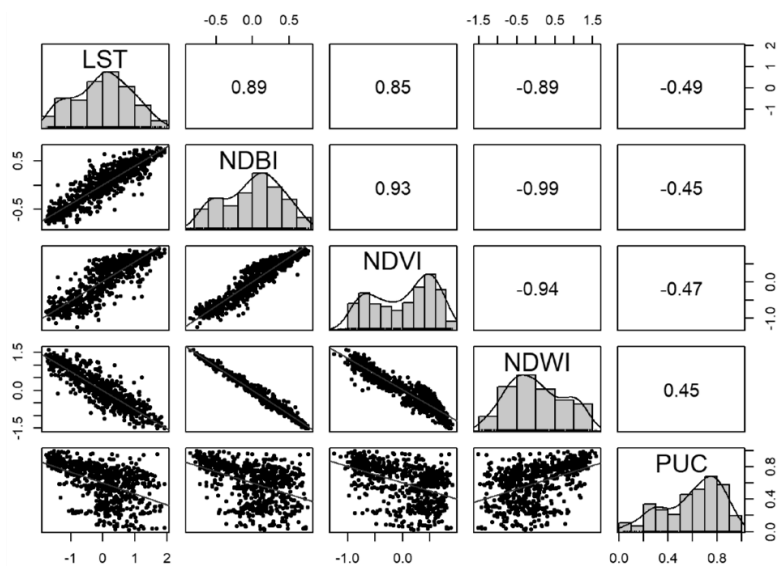


Figura B7. Correlación entre variables seleccionadas por el modelo MLR

```
# Verificación supuestos -----
```

```
# SUPUESTO 1: AUTOCORRELACIÓN
```

```
# Se refiere a la similitud entre datos cercanos (redundancia)
```

```
# Estadístico de Durbin-Watson
```

```
#  $1.5 < D-W < 2.5$  para que no exista autocorrelación
```

```
# D-W deberá estar en este rango
```

```
dwt(modelo_def, alternative = "two.sided")
```

##lag	Autocorrelation	D-W Statistic	p-value
##1	0.1023017	2.00793628	0.81

```
# SUPUESTO 2: NORMALIDAD DE RESIDUOS
# los residuos deben seguir comportamiento normal
# Prueba de Kolmogorov-Smirnov; H0: se distribuyen normalmente
# Hi: no se distribuye normalmente. Si p-value > 0.05 se acepta H0
```

```
residuos = -rstandard(modelo_def)
ks.test(x = residuos, "pnorm", mean(residuos), sd(residuos))
```

```
##One-sample Kolmogorov-Smirnov test
##
##data:  residuos
##D = 0.025024, p-value = 0.0679
"##One-sample Kolmogorov-Smirnov test results"
```

```
# Gráficas asociadas a la normalidad de datos
```

```
win.graph()
par(mfrow=c(1,2)) # Divide la ventana en 1 fila, 2 columnas

# Histograma
x2 <- seq(min(x), max(x), length = 40) # Grid del eje X
fun <- dnorm(x2, mean = mean(residuos), sd = sd(residuos)) # Curva normal
hist(residuos, breaks = 40, prob = TRUE, col = "darkgray",
      ylim = c(0, max(fun+0.1)),
      main = "Histograma con curva normal")
      lines(x2, fun, col = 2, lwd = 2)
```




Figura B8. Distribución de frecuencias de residuales del modelo

# Gráfico de cuantiles de los residuos

```
qqnorm(residuos, col = '#0000FF')
```

```
qqline(residuos, col = 2)
```




Figura B9. Gráfica cuantil-cuantil de residuales del modelo

# Gráficas de comparación de residuos

```
ggplot(data = df,
  mapping = aes(x=NDBI, y=residuos)) +
  geom_point(color="#34495E") +
  geom_smooth(color="firebrick") +
  geom_hline(yintercept = 0) +
  labs(x='NDBI', y="residuos", color="Continent") +
  theme_bw()
```




Figura B10. Dispersión de residuos NDVI

```
ggplot(data = df,
  mapping = aes(x=NDVI, y=residuos)) +
  geom_point(color="#34495E") +
  geom_smooth(color="firebrick") +
  geom_hline(yintercept = 0) +
  labs(x='NDVI', y="residuos", color="Continent") +
  theme_bw()
```




Figura B11. Dispersión de residuos NDVI

```
ggplot(data = df,
  mapping = aes(x=NDWI, y=residuos)) +
  geom_point(color="#34495E") +
  geom_smooth(color="firebrick") +
  geom_hline(yintercept = 0) +
  labs(x='NDWI', y="residuos", color="Continent") +
  theme_bw()
```




Figura B12. Dispersión de residuos NDWI

```
ggplot(data = df,
       mapping = aes(x=PUC, y=residuos)) +
  geom_point(color="#34495E") +
  geom_smooth(color="firebrick") +
  geom_hline(yintercept = 0) +
  labs(x='PUC', y="residuos", color="Continent") +
  theme_bw()
```




Figura B13. Dispersión de residuos PUC

*# Homocedasticidad*

```
ggplot(data = df,
       mapping = aes(modelo_def$fitted.values, modelo_def$residuals)) +
  geom_point(color="#34495E") +
  geom_smooth(method = 'lm', se = FALSE, color = "firebrick") +
  geom_hline(yintercept = 0) +
  labs(x='valores ajustados', y="residuos", color = "Continent") +
  theme_bw()
```




Figura B14. Dispersión de valores ajustados del modelo contra sus residuos

*# SUPUESTO 3: MULTICOLINEALIDAD*

*# se refiere a la alta correlación entre variables explicativas*

*# Se mide a través del Índice de Inflación de la Varianza (VIF)*

*# según referencias citadas en la tesis el VIF de cada variable*

*# explicativa debería tener valor máximo de 10*

`vif(modelo_def)`

##NDBI	NDVI	NDWI	PUC
##44.034063	9.122762	45.751829	1.261277

*# Coeficientes estandarizados Beta y aporte -----*

`X <- coef(modelo_def)`

*# Calcula cada coeficiente beta*

*# X[i] indica la posición i del vector X*

`beta_NDBI = X[2] * (sd(df$NDBI) / sd(df$LST))`

`beta_NDVI = X[3] * (sd(df$NDVI) / sd(df$LST))`

`beta_NDWI = X[4] * (sd(df$NDWI) / sd(df$LST))`

`beta_PUC = X[5] * (sd(df$PUC) / sd(df$LST))`

*# Lleva los coeficientes beta a un vector*

```

Coef_beta = c(beta_NDBI, beta_NDVI, beta_NDWI, beta_PUC)
Coef_beta

# Expresa el vector de coeficientes en valor absoluto
Y = abs(Coef_beta)

# Suma los compones del vector Y
suma = sum(Y)

# Calcula el aporte porcentual de los
# coeficientes beta a la variable dependiente
Aporte_NDBI = (Y[1]/suma)*100
Aporte_NDVI = (Y[2]/suma)*100
Aporte_NDWI = (Y[3]/suma)*100
Aporte_PUC = (Y[4]/suma)*100

# Expresa los porcentajes de aporte de cada variable al modelo
Aporte_modelo = c(Aporte_NDBI, Aporte_NDVI, Aporte_NDWI, Aporte_PUC)
Aporte_modelo

```

##NDBI	NDVI	NDWI	PUC
##21.38149	12.84450	51.46192	14.32108

## Apéndice D. Código fuente de implementación WNB

```
%***** MODELACION WEIGHTED NAÏVE BAYES (WNB) *****

% Programadores: IMS, JGB
% Lenguaje      : Matlab
% Fecha        : Enero 2021
% Objetivo     : Implementar el modelo WNB para segmentar el espacio
%               geográfico en unidades de diferente intensidad LST
% Entradas    : (1) Prob. a priori de cada clase de entrenamiento
%               (2) Factores descriptores LST en estructura de vector
%               (3) Peso de cada factor obtenido desde el MLR
%               (4) PDF de mejor ajuste para cada factor y cada clase
% Salida      : Imagen en formato .gif con la segmentación

%*****

close all; clear; clc;

%***** PROBABILIDADES A PRIORI P(Ci) *****

% fueron calculadas extrayendo el porcentaje de ocupación de cada
% clase sobre el total de área cubierta, se necesitó previamente
% correr el modelo de clasificación SVM.

PC_c7 = 0.11835;
PC_c6 = 0.07024;
PC_c5 = 0.13184;
PC_c4 = 0.24230;
PC_c3 = 0.17442;
PC_c2 = 0.20517;
PC_c1 = 0.05769;
```

```
%***** CARGA DE FACTORES *****
```

```
pc1_ndbi = imread('D:/UPM/4_segmentacion/WNB/bandal_ndbi.tif');  
A = pc1_ndbi';  
pc1_ndbi_Vr = reshape(A,1,[]);  
ndbi = pc1_ndbi_Vr';
```

```
pc1_ndvi = imread('D:/UPM/4_segmentacion/WNB/bandal_ndvi.tif');  
A = pc1_ndvi';  
pc1_ndvi_Vr = reshape(A,1,[]);  
ndvi = pc1_ndvi_Vr';
```

```
pc1_ndwi = imread('D:/UPM/4_segmentacion/WNB/bandal_ndwi.tif');  
A = pc1_ndwi';  
pc1_ndwi_Vr = reshape(A,1,[]);  
ndwi = pc1_ndwi_Vr';
```

```
puc2 = imread('D:/UPM/4_segmentacion/WNB/bandal_puc.tif');  
A = puc2';  
puc2_Vr = reshape(A,1,[]);  
puc = puc2_Vr';
```

```
%***** PESO DE LOS FACOTRES (Wi) *****
```

```
W_ndbi = 0.2138;  
W_ndvi = 0.1284;  
W_ndwi = 0.5146;  
W_puc = 0.1432;
```

```
% ***** FUNCIONES DE DISTRIBUCIÓN DE PROBABILIDAD (PDF) *****
```

```
% Factor = NDBI  
% Clase = 7 (EHT)  
% Distribución = Logistic  
p1 = -0.685266; % parámetro
```

```

p2          = 0.0499304; % parámetro
pd_ndbi_c7 = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c7 = double(pdf(pd_ndbi_c7,ndbi));

% Factor      = NDBI
% Clase       = 6 (HT)
% Distribución = Logistic
p1          = -0.41372; % parámetro
p2          = 0.112962; % parámetro
pd_ndbi_c6 = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c6 = double(pdf(pd_ndbi_c6,ndbi));

% Factor      = NDBI
% Clase       = 5 (SHT)
% Distribución = Logistic
p1          = -0.39922; % parámetro
p2          = 0.0489675; % parámetro
pd_ndbi_c5 = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c5 = double(pdf(pd_ndbi_c5,ndbi));

% Factor      = NDBI
% Clase       = 4 (MT)
% Distribución = Logistic
p1          = -0.0374355; % parámetro
p2          = 0.0550359; % parámetro
pd_ndbi_c4 = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c4 = double(pdf(pd_ndbi_c4,ndbi));

% Factor      = NDBI
% Clase       = 3 (SMT)
% Distribución = Logistic
p1          = 0.329808; % parámetro
p2          = 0.0956724; % parámetro
pd_ndbi_c3 = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c3 = double(pdf(pd_ndbi_c3,ndbi));

```

```

% Factor      = NDBI
% Clase       = 2 (LT)
% Distribución = Logistic
p1            = 0.356072; % parámetro
p2            = 0.0897734; % parámetro
pd_ndbi_c2    = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndbi_c2   = double(pdf(pd_ndbi_c2,ndbi));

% Factor      = NDBI
% Clase       = 1 (SLT)
% Distribución = Normal
p1            = 0.667086; % parámetro
p2            = 0.161129; % parámetro
pd_ndbi_c1    = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndbi_c1   = double(pdf(pd_ndbi_c1,ndbi));

% Factor      = NDVI
% Clase       = 7 (EHT)
% Distribución = Normal
p1            = -0.851722; % parámetro
p2            = 0.0937308; % parámetro
pd_ndvi_c7    = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndvi_c7   = double(pdf(pd_ndvi_c7,ndvi));

% Factor      = NDVI
% Clase       = 6 (HT)
% Distribución = Normal
p1            = -0.466363; % parámetro
p2            = 0.306764; % parámetro
pd_ndvi_c6    = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndvi_c6   = double(pdf(pd_ndvi_c6,ndvi));

% Factor      = NDVI
% Clase       = 5 (SHT)
% Distribución = Normal
p1            = -0.597095; % parámetro
p2            = 0.155084; % parámetro

```

```

pd_ndvi_c5      = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndvi_c5     = double(pdf(pd_ndvi_c5,ndvi));

% Factor        = NDVI
% Clase         = 4 (MT)
% Distribución  = Logistic
p1              = 0.20916; % parámetro
p2              = 0.197479; % parámetro
pd_ndvi_c4      = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndvi_c4     = double(pdf(pd_ndvi_c4,ndvi));

% Factor        = NDVI
% Clase         = 3 (SMT)
% Distribución  = Logistic
p1              = 0.462976; % parámetro
p2              = 0.127868; % parámetro
pd_ndvi_c3      = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndvi_c3     = double(pdf(pd_ndvi_c3,ndvi));

% Factor        = NDVI
% Clase         = 2 (LT)
% Distribución  = Logistic
p1              = 0.455746; % parámetro
p2              = 0.108518; % parámetro
pd_ndvi_c2      = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndvi_c2     = double(pdf(pd_ndvi_c2,ndvi));

% Factor        = NDVI
% Clase         = 1 (SLT)
% Distribución  = Weibull
p1              = 0.881168; % parámetro
p2              = 11.0336; % parámetro
pd_ndvi_c1      = makedist('Weibull','a',p1,'b',p2);
pdf_ndvi_c1     = double(pdf(pd_ndvi_c1,ndvi));

```

```

% Factor      = NDWI
% Clase       = 7 (EHT)
% Distribución = Normal
p1            = 1.27422; % parámetro
p2            = 0.146225; % parámetro
pd_ndwi_c7    = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndwi_c7   = double(pdf(pd_ndwi_c7,ndwi));

% Factor      = NDWI
% Clase       = 6 (HT)
% Distribución = Normal
p1            = 0.7311; % parámetro
p2            = 0.420118; % parámetro
pd_ndwi_c6    = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndwi_c6   = double(pdf(pd_ndwi_c6,ndwi));

% Factor      = NDWI
% Clase       = 5 (SHT)
% Distribución = Weibull
p1            = 0.2887; % parámetro
p2            = 5.616; % parámetro
pd_ndwi_c5    = makedist('Weibull','a',p1,'b',p2);
pdf_ndwi_c5   = double(pdf(pd_ndwi_c5,ndwi));

% Factor      = NDWI
% Clase       = 4 (MT)
% Distribución = Logistic
p1            = 0.0816405; % parámetro
p2            = 0.118455; % parámetro
pd_ndwi_c4    = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndwi_c4   = double(pdf(pd_ndwi_c4,ndwi));

% Factor      = NDWI
% Clase       = 3 (SMT)
% Distribución = Normal
p1            = -0.657172; % parámetro
p2            = 0.287074; % parámetro

```

```

pd_ndwi_c3      = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndwi_c3     = double(pdf(pd_ndwi_c3,ndwi));

% Factor        = NDWI
% Clase         = 2 (LT)
% Distribución  = Normal
p1              = 0.628653; % parámetro
p2              = 0.315707; % parámetro
pd_ndwi_c2     = makedist('Normal','mu',p1,'sigma',p2);
pdf_ndwi_c2     = double(pdf(pd_ndwi_c2,ndwi));

% Factor        = NDWI
% Clase         = 1 (SLT)
% Distribución  = Logistic
p1              = -1.30557; % parámetro
p2              = 0.188707; % parámetro
pd_ndwi_c1     = makedist('Logistic','mu',p1,'sigma',p2);
pdf_ndwi_c1     = double(pdf(pd_ndwi_c1,ndwi));

% Factor        = PUC
% Clase         = 7 (EHT)
% Distribución  = Normal
p1              = 0.85320; % parámetro
p2              = 0.06381; % parámetro
pd_puc_c7      = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c7     = double(pdf(pd_puc_c7,puc));

% Factor        = PUC
% Clase         = 6 (HT)
% Distribución  = Normal
p1              = 0.34715; % parámetro
p2              = 0.15925; % parámetro
pd_puc_c6     = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c6     = double(pdf(pd_puc_c6,puc));

```

```

% Factor      = PUC
% Clase      = 5 (SHT)
% Distribución = Normal
p1           = 0.79538; % parámetro
p2           = 0.06075; % parámetro
pd_puc_c5   = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c5  = double(pdf(pd_puc_c5,puc));

% Factor      = PUC
% Clase      = 4 (MT)
% Distribución = Normal
p1           = 0.5024; % parámetro
p2           = 0.1721; % parámetro
pd_puc_c4   = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c4  = double(pdf(pd_puc_c4,puc));

% Factor      = PUC
% Clase      = 3 (SMT)
% Distribución = Normal
p1           = 0.79538; % parámetro
p2           = 0.06075; % parámetro
pd_puc_c3   = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c3  = double(pdf(pd_puc_c3,puc));

% Factor      = PUC
% Clase      = 2 (LT)
% Distribución = Normal
p1           = 0.34715; % parámetro
p2           = 0.15925; % parámetro
pd_puc_c2   = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c2  = double(pdf(pd_puc_c2,puc));

% Factor      = PUC
% Clase      = 1 (SLT)
% Distribución = Normal
p1           = 0.8532; % parámetro
p2           = 0.06381; % parámetro

```

```

pd_puc_c1      = makedist('Normal','mu',p1,'sigma',p2);
pdf_puc_c1     = double(pdf(pd_puc_c1,puc));

%***** PROBABILIDADES A POSTERIORI*****

%P_c7 =
((W_ndbi*pdf_ndbi_c7)*(W_ndvi*pdf_ndvi_c7)*(W_ndwi*pdf_ndwi_c7)*(W_puc
*pdf_puc_c7))*(PC_c7);

% debido a la dimensión de las matrices no se puede multiplicar
linealmente

% por tanto, se hará por bloques.

p_c7_parte1 = times(W_ndbi*pdf_ndbi_c7,W_ndvi*pdf_ndvi_c7);
p_c7_parte2 = times(W_ndwi*pdf_ndwi_c7,W_puc*pdf_puc_c7)*(PC_c7);
p_c7        = times(p_c7_parte1,p_c7_parte2);

p_c6_parte1 = times(W_ndbi*pdf_ndbi_c6,W_ndvi*pdf_ndvi_c6);
p_c6_parte2 = times(W_ndwi*pdf_ndwi_c6,W_puc*pdf_puc_c6)*(PC_c6);
p_c6        = times(p_c6_parte1,p_c6_parte2);

p_c5_parte1 = times(W_ndbi*pdf_ndbi_c5,W_ndvi*pdf_ndvi_c5);
p_c5_parte2 = times(W_ndwi*pdf_ndwi_c5,W_puc*pdf_puc_c5)*(PC_c5);
p_c5        = times(p_c5_parte1,p_c5_parte2);

p_c4_parte1 = times(W_ndbi*pdf_ndbi_c4,W_ndvi*pdf_ndvi_c4);
p_c4_parte2 = times(W_ndwi*pdf_ndwi_c4,W_puc*pdf_puc_c4)*(PC_c4);
p_c4        = times(p_c4_parte1,p_c4_parte2);

p_c3_parte1 = times(W_ndbi*pdf_ndbi_c3,W_ndvi*pdf_ndvi_c3);
p_c3_parte2 = times(W_ndwi*pdf_ndwi_c3,W_puc*pdf_puc_c3)*(PC_c3);
p_c3        = times(p_c3_parte1,p_c3_parte2);

p_c2_parte1 = times(W_ndbi*pdf_ndbi_c2,W_ndvi*pdf_ndvi_c2);
p_c2_parte2 = times(W_ndwi*pdf_ndwi_c2,W_puc*pdf_puc_c2)*(PC_c2);
p_c2        = times(p_c2_parte1,p_c2_parte2);

p_c1_parte1 = times(W_ndbi*pdf_ndbi_c1,W_ndvi*pdf_ndvi_c1);

```

```

p_c1_parte2 = times(W_ndwi*pdf_ndwi_c1,W_puc*pdf_puc_c1)*(PC_c1);
p_c1       = times(p_c1_parte1,p_c1_parte2);

%**** CONSTRUCCIÓN DE LA MATRIZ A PARTIR DE LAS PROB. APOSTERIORI****

PT = [p_c1,p_c2,p_c3,p_c4,p_c5,p_c6,p_c7];

%***** BÚSQUEDA DE MÁXIMOS E ÍNDICES EN LA MATRIZ*****

[m,idx] = max(PT,[],2); % m: almacena el máximo ; idx: almacena el
índice del máximo

%***** CONVERSIÓN DE IDX A MATRIZ Y CREACIÓN ARCHIVO GIF*****

idx_vr = idx'; % se transpone el arreglo
K       = reshape(idx_vr,813,[]); % 813 es el número de columnas que
debe tener la imagen de salida
RES_M   = K';
imwrite(RES_M,'salida_nb1.gif');

%***** VISUALIZACIÓN DE LA MATRIZ*****

figure; imagesc(RES_M); % muestra la matriz como imagen con rango de
colores

%***** FIN DEL PROGRAMA*****

```