



ANÁLISIS ESPACIOTEMPORAL DEL FENÓMENO ISLAS DE CALOR URBANO Y SU RELACIÓN CON FACTORES BIOFÍSICOS EXTRAÍDOS DE IMÁGENES MULTIESPECTRALES USANDO TÉCNICAS PCA – MLR

Julián Garzón

**Universidad Politécnica de Madrid
Madrid, España**

**Universidad del Quindío
Armenia, Colombia**

Iñigo Molina, Jesús Velasco

**Universidad Politécnica de Madrid
Madrid, España**

Resumen

Los estudios que relacionan el creciente fenómeno de urbanización y medio ambiente térmico atraen la mirada de muchos científicos alrededor del mundo. La temperatura de la superficie terrestre es considerada una variable biofísica fundamentales para una amplia variedad de estudios de la atmósfera superficial. El fenómeno de Islas de Calor Urbano Superficial (SUHI) se refiere al aumento térmico de las áreas urbanas frente a las rurales circundantes, asociado a la capacidad de retención de energía calórica de los materiales de construcción. Este estudio investigó la influencia de la urbanización en el entorno térmico urbano, así como las relaciones de la temperatura superficial terrestre con otras variables biofísicas en Cartago-Colombia, usando 37 imágenes de las series Landsat TM/ETM + y OLI/TIRS adquiridas entre 2001 y 2020. La metodología para la caracterización del fenómeno utilizó técnicas estadísticas de Análisis de Componentes Principales (PCA) y Regresión Lineal Múltiple (MLR), que permitieron detectar las tendencias térmicas espaciotemporales y definir el aporte de cada variable sobre el modelo. Se evaluaron las técnicas de Aprendizaje Automático: Support Vector Machine y Random Forest para la identificación de zonas con propiedades térmicas similares. La ciudad ha experimentado un

aumento de 2.7 °C entre la última década y la anterior. Los resultados de las métricas de calidad de los clasificadores indicaron que la caracterización del fenómeno fue confiable. La información de los patrones térmicos multitemporales, y la identificación de zonas extremadamente calientes sobre los paisajes urbanos, podrían ser de interés para los planificadores del territorio que buscan minimizar los efectos del fenómeno SUHI.

Palabras clave: temperatura superficial terrestre; sensores remotos; resiliencia urbana

Abstract

Studies linking the growing phenomenon of urbanization and the thermal environment attract the eyes of many scientists around the world. Earth's surface temperature and emissivity are fundamental biophysical variables for a wide variety of studies of the surface atmosphere. The phenomenon of Superficial Urban Heat Islands (SUHI) refers to the thermal increase in urban areas compared to the surrounding rural areas, associated with the heat energy retention capacity of construction materials. This study investigated the influence of urbanization on the urban thermal environment, as well as the relationships of the terrestrial surface temperature with other biophysical variables in Cartago, Colombia, using 37 images from the Landsat TM / ETM + and OLI / TIRS series acquired between 2001 and 2020. The methodology for the characterization of the phenomenon used the statistical techniques of Principal Component Analysis (PCA) and Multiple Linear Regression (MLR), which allowed detecting the spatiotemporal thermal trends and defining the contribution of each variable to the model. Two Machine Learning techniques, Support Vector Machine and Random Forest, were evaluated for the identification of zones with similar thermal properties. The city has experienced an increase of 2.7 ° C between the last decade and the previous one. The results of the quality metrics of the classifiers indicated that the characterization of the phenomenon was reliable. Information on multitemporal thermal patterns and the identification of extremely hot zones in urban landscapes could be of interest to land planners seeking to minimize the effects of the SUHI phenomenon.

Keywords: land surface temperature; remote sensing; urban resilience

1. Introducción

Los cambios en el uso y cobertura del suelo generan gran impacto en la infraestructura de las ciudades haciéndose perceptibles en sus características ecológicas y físicas (Hereher, 2017). Entre los diversos problemas ambientales asociados con la actividad humana en las ciudades, el fenómeno de Islas de Calor Urbano Superficial (SUHI) ha sido definido como la diferencia térmica entre áreas urbanas y sus zonas circundantes. El calentamiento de las ciudades y la formación SUHI son el resultado de la transformación del suelo y generan interés en diversas disciplinas científicas dado que, afectan la salud humana, la función del ecosistema y el clima local (Imhoff et al., 2010). El aumento térmico superficial es ocasionado por materiales de construcción altamente impermeables que provocan reducción en el flujo de calor latente y aumento en el calor sensible. Comprender la distribución de la temperatura superficial terrestre (LST) y su variación espacio-



temporal resulta útil para descifrar su mecanismo y caracterizar el fenómeno SUHI. En consecuencia, la LST recuperada de imágenes producidas por sensores remotos, se ha aplicado ampliamente para estudiar el patrón espacial térmico y sus relaciones con las características de la superficie urbana (Chen & Zhang, 2017).

Diversos índices espectrales diferenciales normalizados como, el de vegetación (NDVI), el de construcción (NDBI), y el de agua (NDWI) se han utilizado para investigar considerablemente las relaciones entre LST y su impacto sobre la superficie, sugiriendo que los espacios verdes urbanos y húmedos tienen efectos de enfriamiento que disminuyen potencialmente las SUHI (Li et al., 2013) (Tan & Li, 2013) (Feng et al., 2019). La identificación de factores dominantes de LST es fundamental para aliviar el efecto SUHI y mejorar las condiciones térmicas urbanas. En este proyecto se analizarán diferentes índices espectrales como NDVI, NDBI, NDWI, además, factores de proximidad como la distancia a ríos o cuerpos de agua (PW) y al centro urbano (PUC), que se han considerado como factores biofísicos. Comprender la dinámica de LST y sus factores asociados puede mejorar la conciencia del cambio ambiental regional y apoyar el desarrollo sostenible.

El aporte de este trabajo se basa en el desarrollo de un modelo metodológico que detecte las áreas de estrés térmico en la zona urbana del municipio de Cartago-Colombia, a través de: (1) evaluar la relación entre las tendencias espaciotemporales de LST y los factores biofísicos que lo componen, mediante el uso de dos técnicas estadísticas: Análisis de Componentes Principales (PCA) y Regresión Lineal Múltiple (MLR); y (2) caracterizar el fenómeno evaluado a través de dos algoritmos de Aprendizaje Automático: Support Vector Machine (SVM) y Random Forest (RF).

2. Área de estudio, materiales y métodos

2.1 Área de estudio

La zona urbana de Cartago-Valle del Cauca, se encuentra al centro-occidente de Colombia (Lat.: 4.75°N; Long.: 75.9°W) con topografía plana, y extensión de 279 km². La ciudad se encuentra emplazada por la confluencia de los ríos Cauca y La Vieja como se indica en la Figura 1. La ciudad es cubierta por la escena Landsat path 009/row 057.




Figura 1. Ubicación del área de estudio. (Fuentes: ESRI, países WGS84. Geoportal DANE, Colombia).



Cartago es atravesada por la carretera Panamericana que hace parte de la troncal de occidente. Este corredor vial primario opera como núcleo funcional de la subregión del norte y centro del departamento, conecta los principales centros de producción y consumo agrícola desde el noroccidente hasta el suroccidente del país con el puerto marítimo de Buenaventura.

2.2 Materiales

En este manuscrito, el fenómeno SUHI se analiza utilizando el producto LST obtenido de imágenes satelitales de las misiones Landsat 5TM, Landsat 7 ETM+ y Landsat 8 OLI/TIRS, durante el período 2001-2020. En total se usaron 37 imágenes Landsat.

2.3 Métodos

El presente estudio se basa en un modelo metodológico que integra diferentes fuentes de datos derivados de imágenes satelitales, procedimientos de campo y análisis estadísticos, que permiten caracterizar y mapear los factores aportantes al fenómeno SUHI formado en Cartago. Para lograrlo, se han llevado a cabo las siguientes etapas (1) procesamiento de imágenes satelitales; (2) definición de factores biofísicos; (3) recuperación de LST; (4) modelación del fenómeno.

2.3.1 Procesamiento de imágenes satelitales

La conversión de ND a valores de reflectancia superficial se realizó con el software ENVI 5.3 aplicando herramientas de calibración radiométrica. Se ejecutó el módulo *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) para disminuir la influencia de efectos atmosféricos sobre los datos registrados en las bandas de los espectros visible e infrarrojo cercano. Este procedimiento se hizo previo al cálculo de los diferentes índices espectrales y otros factores que se analizaron como influenciadores de LST.

2.3.2 Definición de factores biofísicos

Las cubiertas de la superficie terrestre afectan en gran medida el comportamiento de LST. La textura urbana y el calor antropogénico son fuentes que determinan el calentamiento de la ciudad. En este trabajo se han definido los factores biofísicos como la unión de distintos índices espectrales, transformaciones y variables de proximidad que caracterizan las propiedades físicas de la superficie. Se eligieron tres índices espectrales: NDBI, NDVI, NDWI; y dos variables de proximidad: una a los cuerpos de agua (WP) y otra al centro urbano (PUC).

El NDVI, es un parámetro que refleja el crecimiento de la vegetación. Se ha elegido como factor explicativo de LST por el alto grado de sensibilidad ocasionado por la interacción entre la radiación solar y la cubierta vegetal (Le & Liou, 2021). De acuerdo con Gusso et al., (2017) Las propiedades térmicas del suelo varían según el contenido de humedad, así mismo, las superficies impermeables poseen alta capacidad calórica y conductividad térmica que pueden generar desequilibrios en el control de temperatura de los cuerpos con su entorno, por este motivo se han elegido NDBI y NDWI. También se produjeron mapas de proximidad a cuerpos de agua (PW) y al centro urbano (PUC), el primero justificado porque su influencia resulta significativa en la transformación del calor latente, proporcionando enfriamiento a través de la evaporación (Gupta et al., 2019). El segundo, porque el centro urbano es el punto principal para el desarrollo de actividades socioeconómicas.

2.3.3 Recuperación de LST



Para convertir los valores de radiancia aparente en radiancia en el tope de la atmósfera (L_{TOA}), se aplicó la corrección de efectos atmosféricos en el espectro térmico usando el algoritmo mono-canal desarrollado por Barsi et al., (2005) referido en la Ecuación 1.

$$L_{TOA} = \tau \cdot \varepsilon \cdot L_T + L_u + \tau \cdot (1 - \varepsilon) \cdot L_d \quad (1)$$

donde, L_{TOA} es la radiancia en el tope de la atmósfera; L_T es la radiancia de un cuerpo negro de temperatura cinética; τ es la transmisividad atmosférica media; L_u y L_d son los valores efectivos de trayectorias atmosféricas de radiancias ascendente y descendente para la fecha y hora de la escena, obtenidos libremente desde <https://atmcorr.gsfc.nasa.gov/>. ε es la emisividad superficial. En este trabajo se usaron los modelos de emisividad desarrollados por Valor & Caselles, (1996). Finalmente, LST se obtuvo usando las constantes de calibración de cada sensor aplicados a la inversión de la ley de Planck, basada en la radiación térmica del cuerpo negro.

2.3.4 Modelación de fenómeno

Este trabajo de investigación desarrolla un modelo para integrar, factores biofísicos derivados de imágenes multiespectrales en un estudio espaciotemporal que involucra sistemas complejos, como la interacción del fenómeno SUHI con la dinámica urbana. La modelación del fenómeno se ha hecho acoplando tres técnicas estadísticas: (1) análisis de componentes principales (PCA), (2) regresión lineal múltiple (MLR) y (3) aplicación de las técnicas de aprendizaje automático, Support Vector Machine (SVM) y Random Forest (RF).

Con las 37 imágenes radiométricamente calibradas, se derivaron LST y los índices espectrales NDBI, NDVI, NDWI para el periodo 2001-2020. Cada variable fue apilada en una estructura ráster independiente con 37 bandas. Para simplificar la complejidad de los datos se usó la técnica PCA que aplica una transformación lineal, obteniendo la representación de los mismos datos con menos dimensiones, y reteniendo la máxima varianza del conjunto original. El PC1 de cada variable contiene la tendencia del conjunto de datos. Para completar las posibles variables explicativas de LST, se adicionaron los mapas de proximidad PW y PUC, definiendo cinco factores biofísicos.

Para determinar la influencia de los factores mencionados sobre el PC1 de LST —es decir, sobre la tendencia de la temperatura entre 2001-2020— se utilizó el método de regresión lineal múltiple (MLR) *step-by-step*. Finalmente, utilizando el principio de definición de rangos térmicos de Wu et al., (2019) se extrajeron siete clases que sirvieron para determinar las áreas de entrenamiento de los clasificadores SVM y RF.

3. Resultados

Aplicando el modelo recuperación de LST descrito, se obtuvieron los valores medios de cada escena representados en la Figura 2. De manera generalizada, se observan dos rangos de temperatura distintos. Primero, el periodo 2001-2010 muestra diferencias de temperatura mínima-máxima de 17.2 °C a 23.2 °C con temperatura media de 19.2 °C. Luego, durante la década 2010-2020, las variaciones de LST son considerables y oscilan entre 15.3 °C y 25.7 °C con temperatura media de



21.9 °C. Al comparar ambas décadas, se detectó un aumento térmico general de $2.7^{\circ}\text{C} \pm 1.1^{\circ}\text{C}$. La tasa de crecimiento anual de LST en la última década fue de 4.1 %.




Figura 2. Valores medios de LST 2001-2020 (°C)

La aplicación de PCA sobre factores biofísicos permitió obtener el porcentaje de varianza explicada según sus componentes. El porcentaje mayor se obtuvo en el PC1 para todos los casos. La Figura 3 representa el PC1 de la variable dependiente LST. Los mayores valores del PC1 sugieren máximas concentraciones de valores altos de la variable, mientras que los valores menores indican máximas concentraciones de los valores más bajos de la variable. Los valores cercanos a cero señalan estabilidad en el tiempo.




Figura 3. Mapa de tendencia de LST 2001-2020 (°C)

De acuerdo con el modelo de regresión lineal, las variables explicativas de LST fueron NDBI, NDVI, NDWI, y PUC. El coeficiente de determinación múltiple R^2 fue 0.79. La verificación de supuestos del modelo fue satisfactoria.

La calidad de la clasificación se midió a través de la validación interna de Orfeo ToolBox utilizando el 50 % los polígonos de muestra. La Tabla 1 reporta las matrices de confusión, y precisiones del usuario y productor. La Tabla 2 reporta la precisión general y el índice Kappa para RF y SVM.

Tabla 1. Matrices de confusión para los algoritmos de clasificación RF y SVM

RF	SL	L	SM	M	SH	H	EH	Total	User's accuracy
Sub-low (SL)	21	0	0	0	0	0	0	21	95.4%
Low (L)	1	19	0	0	0	1	0	21	95.0%
Sub-medium (SM)	0	0	21	0	0	0	0	21	100%
Medium (M)	0	1	0	18	1	1	0	21	94.7%
Sub-high SH)	0	0	0	1	20	0	0	21	86.9%
High (H)	0	0	0	0	0	21	0	21	91.3%
Extreme high (EH)	0	0	0	0	2	0	19	21	100%
Total	22	20	21	19	23	23	19	21	
Producer's accuracy	100 %	90.4 %	100%	85.7%	95.2%	100%	90.4%		
SVM	SL	L	SM	M	SH	H	EH	Total	User's accuracy
Sub-low	21	0	0	0	0	0	0	21	84%
Low	2	18	1	0	0	0	0	21	100%
Sub-medium	2	0	18	1	0	0	0	21	94.7%
Medium	0	0	0	20	1	0	0	21	95.2%
Sub-high	0	0	0	0	21	0	0	21	87.5%
High	0	0	0	0	0	21	0	21	100%
Extreme high	0	0	0	0	2	0	19	21	100%
Total	25	18	19	21	24	21	19	21	
Producer's accuracy	100 %	85.7 %	85.7%	95.2%	100%	100%	90.4%		

Tabla 2. Índice Kappa y precisión general de los clasificadores

Algoritmo	Índice Kappa	Precisión general (%)
RF	0.94	94.56
SVM	0.93	93.88

Las métricas de calidad soportadas en los valores del índice Kappa, RF: 0.94 y SVM: 0.93, demuestran que ambos clasificadores proporcionaron resultados confiables. Aunque SVM obtuvo mejores resultados en las clases Medium y Sub-high, RF logró obtener mayor homogeneidad en sus clasificaciones argumentado en su precisión general: 94.56 %. En ambos algoritmos se detectaron temperaturas extremadamente altas en las zonas de mayor densidad urbana. Contrastando la cantidad de área cubierta entre los clasificadores, la clase Low temperature presentó la máxima diferencia (4.5 %). La mínima se presentó en la clase Sub-low (0.24 %), que es la de mayor frescura térmica. Esto se podría asociar a que, la mayor contribución sobre las capas apiladas se aplicó a NDWI (0.41), presentando alta coincidencia en sus distribuciones espaciales. Las clases restantes obtuvieron diferencias de área en promedio de 1.4 %. Ambos clasificadores señalaron los niveles



de precisión del productor al 100% en las clases Sub-low y High. La precisión de usuario de los clasificadores fue coincidente en la clase Extreme-high: 100 %. La precisión general de RF: 94.56 % fue 0.72 % mayor que la de SVM. Aunque la diferencia fue poca, esta precisión indica que RF presentó mayor capacidad de generalización, explicada por la robustez de su algoritmo, dado que el modelo realiza una selección aleatoria del muestreo para entrenar a cada árbol, y que toma una decisión basado en características efectivas. La estrategia de tomar la decisión final apoyada en la votación combinada, convierte a RF en la mejor opción para ser usado como clasificador superando a SVM. Aunque los dos clasificadores pudieron mapear los diferentes rangos de temperatura con precisión general mayor al 90 %, la clasificación RF obtuvo mayor desempeño: 95.56 %, por lo que fue usado para elaborar el mapa de islas de calor de la ciudad de Cartago de la Figura 4.




Figura 4. Mapa SUHI de tendencia térmica 2001-2020

4. Conclusiones

El objetivo principal de este trabajo se logró con el acoplamiento exitoso de los datos de sensores remotos de diferentes plataformas adquiridos entre 2001-2020 y técnicas estadísticas. La investigación propuesta genera un aporte hacia la comprensión de los cambios térmicos urbanos y sus factores responsables. Los resultados revelaron que, se ha experimentado un aumento significativo de 2.7 °C contrastando los valores medios de LST de las últimas dos décadas. El MLR sugiere que el comportamiento de LST está influenciado por los factores biofísicos NDWI, NDBI, NDVI y PUC. La técnica PCA disminuyó la redundancia entre los datos, logrando que se distinguieran claramente los patrones de cada variable en el PC1. Este estudio propuso una técnica detallada para producir un mapa de tendencias térmicas usando algoritmos de aprendizaje automático. Esta investigación ha demostrado la aplicación del clasificador RF en el mapeo de intensidades SUHI, proporcionando descripciones espacialmente explícitas sobre la distribución del calor urbano. Estas conclusiones permiten que, los planificadores del territorio puedan identificar



las zonas de mayor estrés térmico de la ciudad, y programar acciones de intervención, monitoreo, fortalecimiento y/o preservación.

5. Referencias

- 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 J. Butler (Ed.), *Earth Observing Systems X* (Vol. 5882, Issue 58820E, pp. 1–7). Proceedings of SPIE Vol. 5882. <https://doi.org/10.1117/12.619990>
- Chen, X., & Zhang, Y. (2017). Impacts of urban surface characteristics on spatiotemporal pattern of land surface temperature in Kunming of China. *Sustainable Cities and Society*, 32, 87–99. <https://doi.org/10.1016/j.scs.2017.03.013>
- Feng, Y., Gao, C., Tong, X., Chen, S., Lei, Z., & Wang, J. (2019). Spatial patterns of land surface temperature and their influencing factors: A case study in Suzhou, China. *Remote Sensing*, 11(2). <https://doi.org/10.3390/rs11020182>
- 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. *Egyptian Journal of Remote Sensing and Space Science*, 22(1), 81–93. <https://doi.org/10.1016/j.ejrs.2018.03.007>
- Gusso, A., Silva, A., Boland, J., Lenz, L., & Philipp, C. (2017). Income driven patterns of the urban environment. *Sustainability (Switzerland)*, 9(2), 1–20. <https://doi.org/10.3390/su9020275>
- Hereher, M. E. (2017). Effect of land use/cover change on land surface temperatures - The Nile Delta, Egypt. *Journal of African Earth Sciences*, 126, 75–83. <https://doi.org/10.1016/j.jafrearsci.2016.11.027>
- Imhoff, M. L., Zhang, P., Wolfe, R. E., & Bounoua, L. (2010). Remote sensing of the urban heat island effect across biomes in the continental USA. *Remote Sensing of Environment*, 114(3), 504–513. <https://doi.org/10.1016/j.rse.2009.10.008>
- Le, M. S., & Liou, Y. A. (2021). Spatio-temporal assessment of surface moisture and evapotranspiration variability using remote sensing techniques. *Remote Sensing*, 13(9). <https://doi.org/10.3390/rs13091667>
- Li, X., Zhou, W., & Ouyang, Z. (2013). Relationship between land surface temperature and spatial pattern of greenspace: What are the effects of spatial resolution? *Landscape and Urban Planning*, 114(April 2019), 1–8. <https://doi.org/10.1016/j.landurbplan.2013.02.005>
- Tan, M., & Li, X. (2013). Integrated assessment of the cool island intensity of green spaces in the mega city of Beijing. *International Journal of Remote Sensing*, 34(8), 3028–3043. <https://doi.org/10.1080/01431161.2012.757377>
- Valor, E., & Caselles, V. (1996). Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. *Remote Sensing of Environment*, 57(3), 167–184. [https://doi.org/10.1016/0034-4257\(96\)00039-9](https://doi.org/10.1016/0034-4257(96)00039-9)
- Wu, X., Zhang, L., & Zang, S. (2019). Examining seasonal effect of urban heat island in a coastal city. *PLoS ONE*, 14(6), 1–16. <https://doi.org/10.1371/journal.pone.0217850>

Sobre los autores

- **Julián Garzón:** Ingeniero de Sistemas, Estudiante de Doctorado en el Programa de Doctorado en Ingeniería Geomática de la Universidad Politécnica de Madrid y la Universidad Politécnica de Valencia. Profesor asistente Programa Ingeniería Topográfica y Geomática, Universidad del Quindío-Colombia. j.garzonb@alumnos.upm.es



- **Iñigo Molina:** Ingeniero en Geodesia y Cartografía, Doctor por la Universidad Politécnica de Madrid. Profesor titular Universidad Politécnica de Madrid. inigo.molina@upm.es
- **Jesús Velasco:** Ingeniero Técnico en Topografía, Licenciado en Ciencias Matemáticas, Doctor por la Universidad Politécnica de Madrid. Profesor titular Universidad Politécnica de Madrid. jesus.velasco@upm.es

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la
Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2021 Asociación Colombiana de Facultades de Ingeniería (ACOFI)

