

USO DE HERRAMIENTAS SIG, CAD Y GOOGLE EARTH ENGINE EN EL MODELADO  
DE GRADIENTES TÉRMICOS: CASO ORITO, PUTUMAYO, COLOMBIA

Francisco Javier Cortés García



Universidad de Salamanca

Máster en Geotecnologías Cartográficas para Ingeniería y Arquitectura

Escuela Politécnica Superior de Ávila

Tutores: Diego Gonzales Aguilera y Cristina Sáez Blázquez

Ávila, Septiembre de 2025

## Table of Contenido

1. Resumen .....	4
2. Introducción .....	5
3. Localización Area de Estudio.....	7
4. Planteamiento del problema .....	7
5. Objetivos .....	8
5.1 Objetivo general.....	8
5.2 Objetivos específicos .....	8
6. Marco teórico y conceptual.....	9
6.1 Gradiente geotérmico.....	9
6.2 SIG y análisis especial .....	12
6.3 Google Earth Engine .....	13
6.4 Modelado CAD.....	14
6.4.1 Aplicaciones del modelado CAD en gradientes térmicos.....	15
6.4.2 Ventajas y limitaciones .....	16
7. Metodología.....	17
7.1 Recopilación de datos geotérmicos.....	17
7.1.1 Alcance y localización del Area de Estudio (Orito, Putumayo) .....	19
7.2 Procesamiento de imágenes satelitales.....	22
7.2.1 Calculo de LST en Google Earth Engine .....	23
7.2. Clasificación no supervisada K-means en Google Earth Engine .....	31
7.3 Adquisición de Imágenes e Calculo de índices Espectrales.....	37
7.3.1 Análisis satelital y geoespacial en Arc GIS Pro 3.4 .....	39
7.3.1 Metodología aplicada en el análisis de índices espectrales: caso Orito. ....	39
7.3.3 Calculo de anomalías térmicas .....	41
8. Resultados índices Espectrales.....	42
8.1 Modelo de Procesamiento y cálculo de índices – Model Builder.....	42

8.1 Análisis de Correlación entre LST y los índices espectrales .....	53
8.1.1 Gráficos y Mapas de Calor .....	55
9. Análisis Espacial del Gradiente Geotérmico y Evaluación del Potencial.....	66
9.1 Metodología y Modelo de Procesamiento Gradientes - Model Builder .....	66
9.2 Resultados y Análisis de Gradientes Geotérmicos .....	70
11.0 MDE, MDT y Tecnologías CAD .....	77
11.1 Importancia del MDE en Civil 3D y los Productos Derivados .....	77
11.2 Metodología Integración SIG - CAD .....	78
12.0 Discusiones, conclusiones y Recomendaciones.....	83
13. Bibliografía.....	85
13. Anexos.....	87

## 1. Resumen

El departamento del Putumayo está ubicado en el suroeste de Colombia. Este departamento presenta un gran potencial para el desarrollo de estudios geotérmicos debido a su actividad volcánica y la presencia de recursos geotérmicos. En particular, la región de Orito ha sido identificada como un área de interés para el modelado de gradientes térmicos con el apoyo de tecnologías SIG, CAD y procesamiento de imágenes satelitales.

Este trabajo de fin de máster busca implementar herramientas de análisis espacial y automatización para mejorar la comprensión y visualización de los gradientes térmicos en la región, contribuyendo a futuras investigaciones en energías renovables y planificación territorial.

El presente Trabajo de Fin de Máster tiene como objetivo principal el análisis y modelado de gradientes térmicos en la zona de Orito, Putumayo (Colombia), mediante el uso combinado de herramientas de Sistemas de Información Geográfica (SIG), software de diseño asistido por ordenador (CAD) y Google Earth Engine (GEE). Para ello, se han integrado datos geotérmicos puntuales provenientes del Instituto Geológico Colombiano, imágenes satelitales y modelos digitales del terreno con el fin de representar espacialmente la variación térmica del subsuelo y su relación con la temperatura superficial. El trabajo contempla la generación de productos cartográficos temáticos, la automatización de procesos mediante scripts y la visualización de resultados a través de herramientas 3D. Esta metodología permite no solo visualizar los gradientes térmicos de manera más precisa, sino también establecer una base para su aplicación en estudios de energía geotérmica, planificación territorial e ingeniería ambiental. El desarrollo se realiza de forma completamente reproducible y adaptable a otros entornos geográficos similares.

Palabras clave: Gradiente geotérmico, SIG, Google Earth Engine, CAD, Orito, energía térmica, modelado 3D

## Abstract

The department of Putumayo, located in southwestern Colombia, presents significant potential for geothermal studies due to its volcanic activity and the presence of geothermal resources. In particular, the region of Orito has been identified as an area of interest for modeling thermal gradients with the support of GIS technologies, CAD tools, and satellite image processing.

This master's thesis aims to implement spatial analysis and automation tools to improve the understanding and visualization of thermal gradients in the region, contributing to future research in renewable energies and territorial planning.

The main objective of this Final Master's Project is the analysis and modeling of thermal gradients in the Orito region, Putumayo (Colombia), through the combined use of Geographic Information Systems (GIS), computer-aided design (CAD) software, and Google Earth Engine (GEE). Point-

based geothermal data provided by the Colombian Geological Institute, satellite imagery, and digital elevation models are integrated to spatially represent subsurface thermal variation and its relationship with surface temperature. The project includes the creation of thematic cartographic products, process automation through scripting, and 3D result visualization tools. This methodology not only enables a more precise representation of thermal gradients but also establishes a replicable and adaptable workflow for use in other geographic environments, supporting geothermal energy research, territorial management, and environmental engineering applications.

Keywords: Geothermal gradient, GIS, Google Earth Engine, CAD, Orito, thermal energy, 3D modeling

## **2. Introducción**

Las Geotecnologías desempeñan un papel fundamental en la ingeniería y la arquitectura moderna ya que permiten integrar el componente espacial en todas las fases de diseño, planificación y ejecución de proyectos. A través de herramientas como los Sistemas de Información Geográfica (SIG), la teledetección, el modelado 3D y los entornos CAD, es posible analizar el territorio con precisión, identificar restricciones geológicas, optimizar ubicaciones, evaluar riesgos y simular escenarios constructivos. Estas tecnologías no solo mejoran la toma de decisiones técnicas, sino que también permiten diseñar soluciones sostenibles y adaptadas al contexto físico, legal y ambiental de cada espacio, contribuyendo así a una práctica más eficiente, segura e innovadora. En este trabajo se integran distintas tecnologías, como los Sistemas de Información Geográfica (SIG), el software de diseño asistido por ordenador (CAD), el análisis de imágenes satelitales mediante Google Earth Engine (GEE), y el uso de scripting en Python.

La combinación de estas herramientas permite desarrollar una metodología automatizada y reproducible que facilita tanto el análisis como la representación gráfica de los gradientes térmicos. La motivación central de este estudio es demostrar cómo el uso de herramientas digitales avanzadas puede mejorar significativamente la comprensión espacial de fenómenos térmicos subterráneos y contribuir al análisis espacial de gradientes térmicos como insumo para futuras evaluaciones energéticas o ambientales en zonas de interés geológico.

El presente Trabajo de Fin de Máster se enmarca en el estudio del gradiente geotérmico, un fenómeno físico clave para la exploración de recursos geotérmicos, la planificación territorial y el análisis ambiental. Se define como gradiente geotérmico el incremento de temperatura registrado al profundizar desde la capa más externa de la Tierra la corteza hacia las partes interiores de la misma. Dicho gradiente permite estimar el flujo de calor que se transmite desde las zonas internas de la corteza hacia las externas, y que representa la cantidad de calor geotérmico que se desprende por unidad de superficie y se expresa en MW/m<sup>2</sup>. El gradiente geotérmico observado en la mayor

parte del mundo, conocido como gradiente geotérmico normal, a partir de unos 15-30 m de profundidad, es de unos 1.5 a 3 °C cada 100 m. En ciertas regiones, situadas sobre áreas geológicamente activas de la corteza terrestre, el incremento de la temperatura con la profundidad es muy superior al indicado, dando lugar a un gradiente geotérmico anómalo.

En un contexto global donde las energías renovables ganan cada día más importancia, el análisis del comportamiento térmico del subsuelo representa una herramienta estratégica en regiones con potencial geotérmico, como lo es el suroeste colombiano. El estudio de los gradientes geotérmicos es fundamental en la exploración de recursos energéticos sostenibles. En Colombia, la geotermia se ha convertido en un área de interés debido a su potencial para la generación de energía limpia. El municipio de Orito, ubicado en el departamento del Putumayo, presenta condiciones geológicas y térmicas favorables para la exploración geotérmica, lo que justifica la necesidad de modelar espacialmente sus gradientes térmicos. El Instituto Geológico Colombiano se encuentra en el proceso de recopilación de datos geotérmicos en todo el país y la Zona de estudio está localizada dentro de la cuenca del Putumayo.

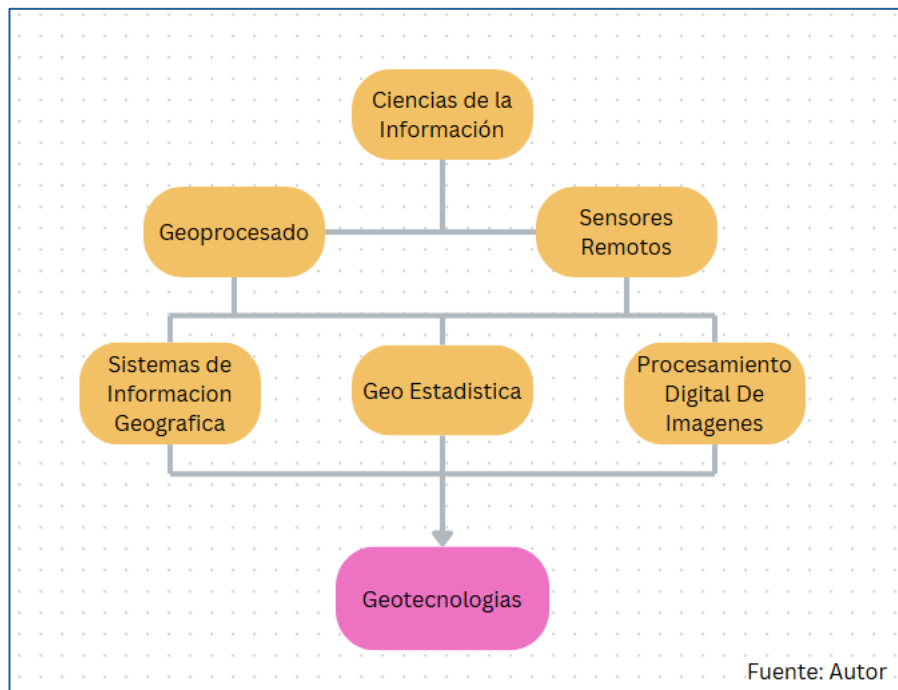


Figura 1. Geotecnologías y las Ciencias de la Información Fuente: Autor

### 3. Localización Area de Estudio

Orito es un municipio situado en el departamento del Putumayo, al suroeste de Colombia, en una región geoestratégica del piedemonte andino-amazónico. Su relevancia radica en su papel como centro de explotación petrolera desde la década de 1960, lo cual ha impulsado un crecimiento poblacional acelerado y una intensa transformación del territorio. El área presenta un clima cálido-húmedo tropical, con temperaturas promedio de 27 °C y lluvias constantes durante gran parte del año, lo que condiciona la dinámica ambiental y el acceso a la infraestructura. Geológicamente, se encuentra en una zona activa donde convergen estructuras tectónicas y manifestaciones termales, lo que ha despertado el interés por el aprovechamiento geotérmico del subsuelo. Esta combinación de factores geográficos, climáticos y geológicos convierte a Orito en un laboratorio natural idóneo para el análisis del gradiente térmico mediante el uso de tecnologías geoespaciales accesibles, permitiendo vincular datos de superficie con parámetros subterráneos a partir de información satelital, puntos de pozo y modelos digitales del terreno.




Figura 2. Municipio de Orito – Putumayo Fuente: Wikipedia

### 4. Planteamiento del problema

En muchas regiones de América del Sur, como el municipio de Orito en el departamento del Putumayo (Colombia), el acceso a tecnologías geoespaciales y metodologías avanzadas de análisis es aún limitado. Pese a contar con recursos naturales estratégicos y datos geotérmicos puntuales generados por entidades como el Instituto Geológico Colombiano, la capacidad técnica local para integrar, analizar e interpretar esa información sigue siendo escasa. Esta carencia no solo dificulta

la toma de decisiones en planificación territorial y energética, sino que también restringe el desarrollo de proyectos sostenibles basados en evidencia espacial.

En este contexto, resulta fundamental explorar cómo el uso de geotecnologías accesibles y de código abierto puede representar un cambio significativo en el análisis territorial. Herramientas geotecnológicas disponibles, como los Sistemas de Información Geográfica (SIG), el software de diseño asistido por ordenador (CAD), Google Earth Engine (GEE), los sensores remotos y los lenguajes de programación, permiten estructurar flujos de trabajo automatizados que integran diversas fuentes de información para generar conocimiento nuevo y visualizable. En particular, este trabajo plantea la hipótesis de que existe una relación espacial significativa entre los gradientes térmicos obtenidos de pozos geotérmicos y la temperatura superficial estimada por imágenes satelitales, lo que permitiría inferir patrones subterráneos con base en datos accesibles y de libre disponibilidad.

Este estudio busca responder a la siguiente pregunta de investigación: ¿Cómo se pueden modelar los gradientes térmicos en Orito, utilizando herramientas SIG y Google Earth Engine para mejorar la caracterización de las condiciones geotérmicas de la región? El problema, por tanto, no radica únicamente en la escasez de datos, sino en la falta de mecanismos técnicos para transformarlos en conocimiento útil. Este TFM propone una metodología que no solo aborda esa brecha en Orito, sino que podría representar una metodología a seguir para el estudio de las tecnologías geoespaciales aplicadas en el campo de geotecnia.

## **5. Objetivos**

### **5.1 Objetivo general**

Implementar herramientas SIG, CAD y Google Earth Engine en el modelado de gradientes térmicos en la región de Orito, Putumayo, con el fin de mejorar la comprensión, visualización y análisis espacial de las variaciones térmicas del subsuelo mediante procesos automatizados y reproducibles.

### **5.2 Objetivos específicos**

- Aplicar herramientas SIG para la recopilación, organización y análisis de registros térmicos existentes en la zona de estudio.
- Utilizar Google Earth Engine para calcular índices térmicos como LST, NDVI y NDWI a partir de imágenes satelitales.
- Integrar los datos procesados en software CAD (Civil 3D) para generar modelos tridimensionales básicos del comportamiento térmico del subsuelo.
- Desarrollar un flujo de trabajo automatizado utilizando Python y GEE para agilizar y reproducir el análisis.

- Validar los resultados mediante la comparación con datos existentes y la generación de mapas temáticos.

## 6. Marco teórico y conceptual

### 6.1 Gradiente geotérmico

El gradiente geotérmico es la tasa de aumento de temperatura con la profundidad en la corteza terrestre, comúnmente expresada en °C/km. Este parámetro permite evaluar el potencial energético del subsuelo, estimar flujos de calor y modelar condiciones geotérmicas a distintas profundidades. Matemáticamente, el gradiente se expresa como:

$$\Gamma = \frac{T_d - T_s}{h}$$

Donde  $T_d$  es la temperatura a la profundidad  $h$  y  $T_s$  es la temperatura superficial. El flujo de calor asociado se puede calcular mediante la ley de conducción de Fourier:

$$q = -\lambda \cdot \frac{dT}{dz}$$

Siendo  $\lambda$  la conductividad térmica del medio geológico.

En condiciones normales, el valor promedio global del gradiente geotérmico es de 25 a 30 °C/km. Sin embargo, este valor varía considerablemente según la geología, tectónica y dinámica hidrotermal.




Figura 3. Gradiente geotérmico

Fuente: Wikipedia

En Colombia, estudios realizados por INGEOMINAS y la Agencia Nacional de Hidrocarburos (ANH) (2009) identificaron anomalías significativas mediante la interpretación de más de 4.400 pozos profundos.

Según el informe técnico oficial, los gradientes en el país oscilan entre 5 y 65 °C/km. En particular, la cuenca Caguán-Putumayo —donde se encuentra el municipio de Orito— presenta gradientes entre 30 y 60 °C/km, evidenciando un alto potencial geotérmico.

Estudios recientes en Colombia confirman estas variaciones regionales. Por ejemplo, en la cuenca Oriente se han reportado gradientes de 21 a 23 °C/km en profundidades de hasta 3.5 km, mostrando un comportamiento térmico diferenciado respecto a otras regiones sedimentarias (Reyes et al., 2023).

Asimismo, en el área geotérmica de Paipa se ha aplicado caracterización resistiva 3D para identificar correlaciones entre estructuras subterráneas y comportamiento térmico, destacando la utilidad de técnicas geofísicas como la magnetotelúrica (González & Rodríguez, 2020).

A nivel internacional, investigaciones en Cataluña (España) han demostrado la viabilidad de generar mapas térmicos tridimensionales mediante algoritmos de aprendizaje profundo (Machine Learning), logrando una precisión superior al 95 % en la estimación de temperaturas subsuperficiales con datos de más de 490 pozos (Martínez et al., 2022). Por otro lado, en regiones del noroeste ibérico, estudios sobre la interacción entre subducción y colisión tectónica revelan cómo la estructura geológica regional influye directamente en el gradiente geotérmico observado (Fernández et al., 2022).

Diversos estudios internacionales refuerzan la viabilidad de metodologías que combinan teledetección, análisis multitemporal LST en GEE y GIS para la estimación del potencial geotérmico. Por ejemplo, Li et al. (2023) emplean GEE para identificar anomalías térmicas en el plateau Qinghai-Tibet, correlacionándolas con lineamientos geológicos visibles en GIS. En China, Zhang et al. (2023) desarrollan un modelo AHP+SIG para predecir zonas geotérmicas y validan sus mapas con manantiales termales existentes. En España, González & Rodríguez-González (2019) utilizan Sentinel-2, ASTER y datos gravimétricos en clasificación aleatoria para identificar zonas con potencial  $\geq 80$  W/m. Finalmente, en Nigeria, Akinola et al. (2021) comprueban que gradientes térmicos  $> 35$  °C/km se correlacionan espacialmente con variables tectónicas y térmicas, usando análisis ROC y evidencia espacial.

En este TFM se utilizaron los valores registrados por el Instituto Geológico Colombiano (IGC) para pozos georreferenciados en Orito. Estos datos se analizaron junto a la temperatura superficial terrestre (LST) procesada en Google Earth Engine, con el objetivo de explorar una posible correlación espacial.

Figura 4. Mapa preliminar Gradiente Geotérmico de Colombia(Scala 1:1500) A través del análisis y el procesamiento de temperaturas medidas en 4144 Pozos en diferentes cencas del país(Fuente: ANH e INGEOMINAS, 2008)

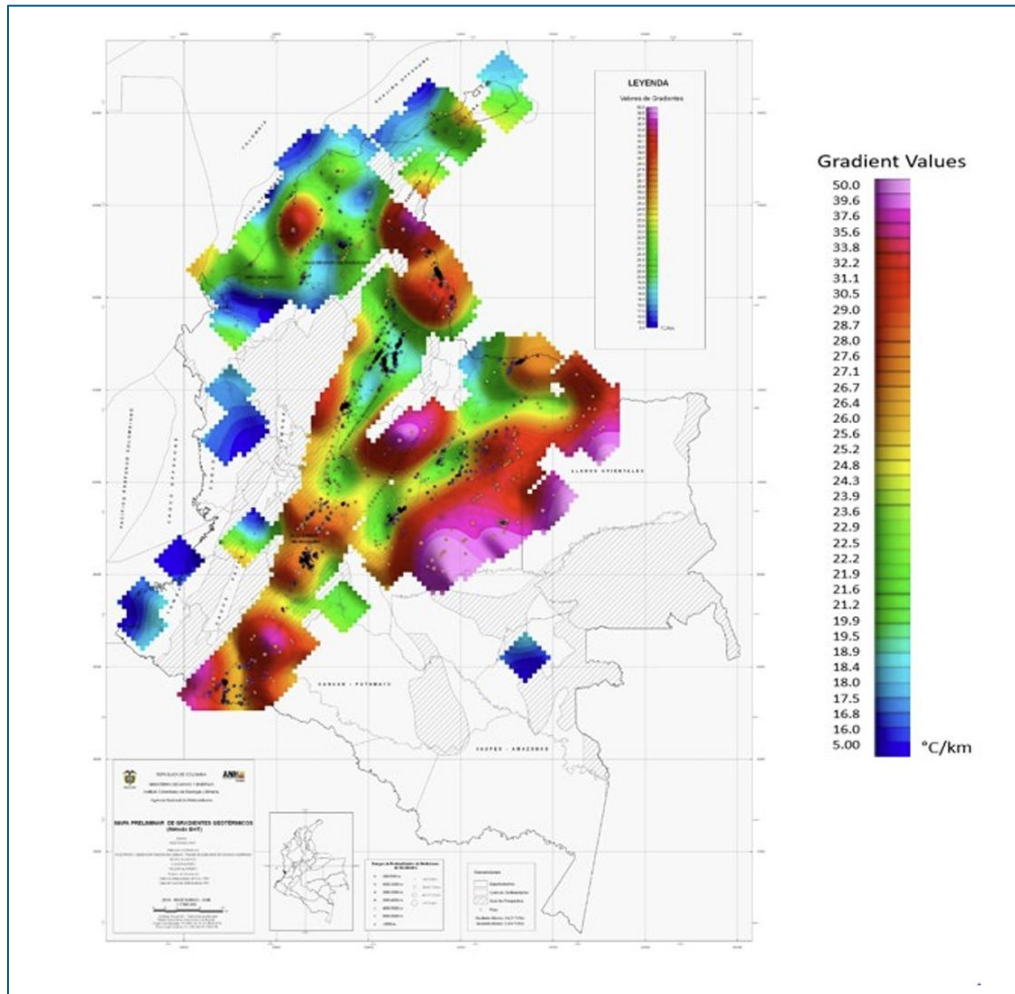


Tabla 1. Gradiente geotérmico promedio por cuenca (INGEOMINAS-ANH)

Cuenca	Gradiente Promedio (°C/Km)
Catatumbo	25.1
Cesar-Ranchería	22.7
Cordillera Oriental	28.4
Llanos Orientales	33.9
Caguán-Putumayo	37.6
Valle Superior del Magdalena	29.2
Valle Medio del Magdalena	32.8
Valle Inferior del Magdalena	30.5

## 6.2 SIG y análisis especial

Los Sistemas de Información Geográfica (SIG) representan una de las herramientas más eficaces para integrar, analizar y visualizar datos geospaciales con fines científicos, técnicos y de planificación. En el ámbito de la geotermia, permiten correlacionar variables superficiales y subterráneas, facilitando la comprensión de los patrones térmicos regionales mediante mapas temáticos, modelos digitales y estadísticas espaciales.

En este Trabajo de Fin de Máster, los SIG fueron fundamentales para estructurar la información geotérmica del municipio de Orito (Putumayo), incluyendo los gradientes térmicos proporcionados por el Instituto Geológico Colombiano (IGC), datos topográficos, imágenes satelitales y variables climáticas. Se utilizaron tanto ArcGIS Pro como QGIS para realizar múltiples procesos, entre ellos:

- Interpolación espacial de gradientes térmicos mediante métodos IDW y kriging.
- Análisis de densidad y distribución espacial.
- Generación de perfiles térmicos y superficies rasterizadas.
- Integración de datos LST derivados de Google Earth Engine.

Las plataformas QGIS y ArcGIS Pro permitieron ejecutar herramientas especializadas para generar superficies interpoladas precisas, automatizar tareas y generar simbologías cartográficas interpretables. Este flujo de trabajo permitió identificar zonas potencialmente anómalas desde el punto de vista térmico, que posteriormente fueron contrastadas con datos LST.

Estudios recientes refuerzan la utilidad de estas herramientas. Li et al. (2023) utilizaron GEE y SIG para analizar series multitemporales de temperatura superficial en el Tíbet, demostrando que su integración permite localizar zonas de anomalía térmica con alta precisión, especialmente cuando se combinan con información geológica vectorial. Zhang et al. (2023), en China, combinaron datos satelitales, geofísicos y SIG mediante el método de Análisis Jerárquico de Proceso (AHP) para generar mapas de potencial geotérmico que fueron validados con presencia real de fuentes termales.

Por su parte, en contextos urbanos europeos, González y Rodríguez-Gonzálvez (2019) mostraron que el uso de SIG combinado con imágenes ASTER y Sentinel-2 puede identificar zonas con potencial térmico elevado ( $>80 \text{ W/m}^2$ ), a través de técnicas de clasificación por aprendizaje automático. En África, Akinola et al. (2021) confirmaron que el análisis espacial mediante modelos estadísticos y herramientas GIS permite detectar relaciones significativas entre gradientes térmicos elevados y variables tectónicas o geológicas.

Estas experiencias coinciden con la estrategia metodológica de este TFM, que propone una cadena de procesamiento reproducible, escalable y adaptable a otros territorios. Como afirma el USGS (2023), "el análisis espacial es clave para reducir la incertidumbre en la exploración geotérmica

inicial, y los SIG proporcionan el marco técnico para la integración sistemática de datos multiescala".

En conjunto, el uso de SIG en este estudio no solo permitió visualizar y contextualizar los gradientes geotérmicos de Orito, sino también comprobar que tecnologías geoespaciales accesibles pueden tener un impacto significativo en territorios con baja infraestructura tecnológica, favoreciendo el desarrollo de metodologías robustas de análisis territorial basadas en datos abiertos y replicables.

### 6.3 Google Earth Engine

La integración de tecnologías de teledetección y análisis satelital se ha convertido en una herramienta esencial para la exploración ambiental, el monitoreo del territorio y el estudio de fenómenos geotérmicos. En este contexto, Google Earth Engine (GEE) se destaca como una plataforma de análisis geoespacial que permite procesar datos satelitales a gran escala de forma automatizada, sin requerir infraestructura local avanzada.

Desarrollada por Google, GEE proporciona acceso a colecciones históricas y recientes de imágenes de sensores como Landsat, MODIS y Sentinel, así como a herramientas de análisis espacial, estadísticas zonales y modelado multitemporal. Su capacidad para manejar grandes volúmenes de datos en la nube ha transformado la manera en que se abordan los estudios de cambio ambiental, cobertura del suelo y condiciones térmicas de la superficie terrestre.

La teledetección térmica, en particular, ha demostrado ser una fuente valiosa de información indirecta para la exploración geotérmica. Varios estudios recientes han mostrado cómo la temperatura superficial terrestre (LST), derivada de sensores térmicos satelitales, puede reflejar manifestaciones térmicas relacionadas con gradientes geotérmicos subyacentes. Chao et al. (2023) analizaron series temporales de LST con GEE en la cuenca de Ruili (China), encontrando una relación significativa entre zonas de alta temperatura superficial y pozos geotérmicos activos. De forma similar, Zhan et al. (2023) identificaron patrones térmicos sobre fallas volcánicas del sudeste asiático mediante el uso combinado de GEE y datos geológicos vectoriales.

En un enfoque más técnico, Li et al. (2025) emplearon Landsat y ASTER en GEE para detectar anomalías térmicas mediante análisis multitemporal corregido por altitud, lo cual permitió validar zonas geotérmicas con alta precisión. Estas experiencias indican que la plataforma no solo facilita el acceso a datos, sino que también permite su integración con modelos de gradiente térmico, mejorando la fiabilidad en la detección de recursos geotérmicos potenciales.

Además, Muanza et al. (2023) aplicaron metodologías similares en Islandia, integrando imágenes térmicas de satélite con datos de dron para validar la evolución de zonas térmicamente activas

durante más de 15 años. Esta combinación de plataformas ha sido clave para estudios donde el acceso a zonas remotas dificulta las campañas de campo tradicionales.

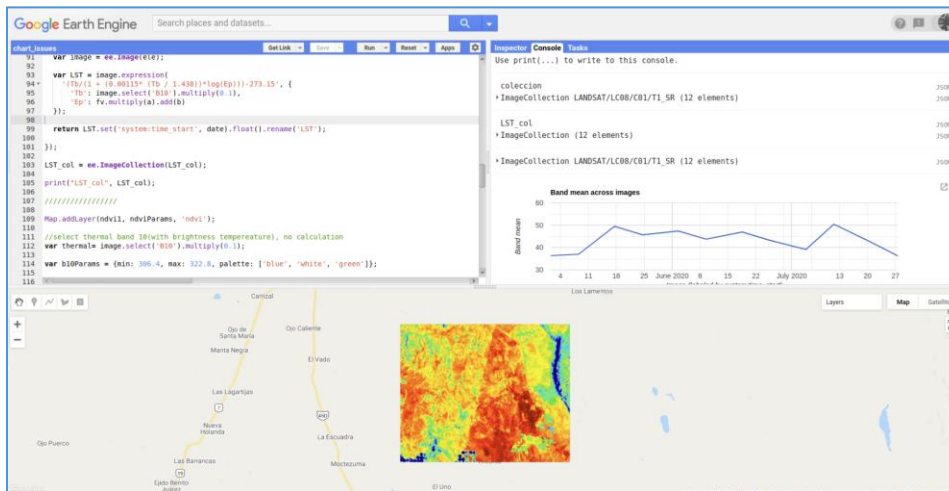


Figure 5. GEE y Teledetección

Fuente: <https://gis.stackexchange.com/>

Estos antecedentes consolidan el valor de GEE como una herramienta estratégica para investigaciones en territorios como Orito (Putumayo), donde el acceso a tecnologías avanzadas es escaso. La posibilidad de automatizar flujos de trabajo y reutilizar scripts genera beneficios tanto académicos como operativos. Como señalan múltiples autores, esta plataforma impulsa la democratización del análisis espacial y ofrece un marco técnico robusto para vincular la superficie terrestre con fenómenos subsuperficiales relacionados con el calor del interior terrestre.

En el marco del presente Trabajo de Fin de Máster, se ha valorado el uso de GEE no como un simple recurso técnico, sino como una vía para proponer nuevas metodologías accesibles, automatizables y basadas en datos abiertos. Su uso es coherente con los principios de ciencia abierta, reproducibilidad y eficiencia operativa, y responde a la necesidad de contar con herramientas que posibiliten el análisis territorial en entornos donde la infraestructura científica aún es limitada.

#### 6.4 Modelado CAD

El modelado asistido por ordenador (CAD, por sus siglas en inglés) constituye una de las herramientas esenciales para la representación tridimensional de datos geoespaciales en ingeniería y geociencias. En el contexto de la exploración y análisis de recursos geotérmicos, el uso de software CAD —como Autodesk Civil 3D— permite generar, editar y visualizar modelos que integran información superficial y subsuperficial, facilitando la comprensión espacial de fenómenos complejos como los gradientes térmicos.

A diferencia de las plataformas SIG, cuyo objetivo principal es la gestión y el análisis espacial de datos, el modelado CAD se orienta hacia la construcción de geometrías precisas y su representación en un entorno tridimensional interactivo. Esto lo convierte en una herramienta complementaria para visualizar de manera tangible la relación entre variables geotérmicas (p. ej., temperatura a distintas profundidades) y elementos del terreno (relieve, infraestructuras, usos del suelo), posibilitando el desarrollo de modelos que sirvan tanto para análisis técnico como para comunicación de resultados a públicos especializados y no especializados.

La relación entre entornos CAD y SIG ha evolucionado significativamente en la última década. Actualmente, Civil 3D admite la importación y exportación de formatos geoespaciales estándar, como LandXML, shapefile, TIN o superficies raster, que permiten transferir datos procesados en SIG (por ejemplo, mapas de temperatura superficial terrestre derivados de Google Earth Engine) a un modelo CAD tridimensional. De este modo, es posible superponer, en un mismo espacio de trabajo, modelos de gradiente térmico, modelos digitales del terreno (MDT) y datos vectoriales (pozos, fallas, redes).

En estudios geotérmicos, esta interoperabilidad resulta clave. Según Witter et al. (2018), los modelos tridimensionales ofrecen un marco visual integrador que permite a los investigadores evaluar, con mayor claridad, las relaciones espaciales entre diferentes conjuntos de datos geocientíficos. Sin embargo, estos autores advierten que la utilidad del modelo depende directamente de la calidad, resolución y confiabilidad de las fuentes originales, por lo que su interpretación debe realizarse de manera crítica y considerando los márgenes de incertidumbre.

#### 6.4.1 Aplicaciones del modelado CAD en gradientes térmicos

El modelado CAD para gradientes térmicos puede abordar diferentes escalas y finalidades tales como la visualización de superficies térmicas, modelos de volumen, la integración con datos topográficos y de infraestructura o la generación de perfiles y secciones transversales. A partir de datos interpolados (IDW, Kriging u otros métodos), se generan superficies TIN o mallas 3D que representan la distribución espacial del gradiente térmico en superficie o a una determinada profundidad. Estas superficies pueden colorearse en función de rangos de temperatura o de valores de gradiente ( $^{\circ}\text{C}/\text{km}$ ), facilitando la identificación de zonas anómalas.

En casos donde se dispone de datos a múltiples profundidades (por ejemplo, temperaturas registradas en diferentes tramos de un pozo), es posible construir sólidos 3D que simulen la variación térmica en el subsuelo (Modelo de Volumen). Esto permite una representación volumétrica del recurso geotérmico, que resulta especialmente útil en fases de planificación de perforaciones o estimación de potencial energético.

Civil 3D permite incorporar el relieve real del terreno, obtenido de MDT o LIDAR, y superponerlo con elementos construidos (vías, edificaciones, redes energéticas). En el contexto geotérmico, esto

es valioso para evaluar la accesibilidad a zonas con alto potencial y planificar infraestructuras de aprovechamiento. Las herramientas de perfilado de Civil 3D permiten extraer secciones verticales a lo largo de líneas definidas, mostrando la variación térmica en relación con la topografía y otros elementos geológicos. Esto contribuye a comprender la continuidad lateral y vertical de las anomalías térmicas. Aunque el uso específico de Civil 3D en geotermia ha sido menos documentado que en áreas como la ingeniería civil o la minería, existen experiencias en proyectos geotécnicos y ambientales que son extrapolables.

En la integración de Civil 3D con ArcGIS Pro, por ejemplo, Esri (2024) ha mostrado cómo es posible intercambiar superficies TIN y modelos de elevación entre ambas plataformas manteniendo la precisión geométrica y altimétrica. Este tipo de integración es directamente aplicable a gradientes térmicos, ya que los modelos de temperatura pueden tratarse como superficies análogas a un MDT, pero con un valor temático distinto.

Asimismo, estudios en ingeniería geotécnica han empleado Civil 3D para modelar subsuelos a partir de sondeos y datos de laboratorio, generando representaciones estratigráficas que se asemejan al modelado de capas térmicas. En el ámbito de la geotermia, la lógica de trabajo es similar: se parte de puntos muestreados (pozos geotérmicos) y se interpolan valores para generar una superficie o volumen.

#### 6.4.2 Ventajas y limitaciones

Entre las ventajas del modelado CAD en geotermia se destacan la alta precisión geométrica ya que posible trabajar con coordenadas y elevaciones exactas, a Interactividad que permite la manipulación libre del modelo para visualizarlo desde diferentes perspectivas, la compatibilidad: importación o exportación de múltiples formatos geoespaciales y finalmente la capacidad de presentación es decir la posibilidad de presentar modelos visualmente atractivos para informes y presentaciones.

No obstante, también existen limitaciones que deben considerarse. De este modo podríamos mencionar su alta dependencia de la calidad de los datos, ya que un modelo 3D es tan fiable como los datos que lo alimentan. Adicionalmente, se puede mencionar la sobrecarga de detalle en un momento dado, es decir, que se pueden presentar modelos excesivamente complejos que dificulten la interpretación de estos y finalmente se destaca como una visible limitación la necesidad de hardware y licencias especializadas que representa un alto coste para la ejecución de los proyectos geotérmicos.

Como advierte Witter et al. (2018), un modelo tridimensional no debe asumirse como una representación exacta de la realidad, sino como una herramienta de apoyo que sintetiza información y facilita la exploración de hipótesis.

En el contexto de este Trabajo de Fin de Master para el área de Orito, Putumayo, el modelado CAD tiene una doble relevancia ya que se busca que la tecnología CAD sirvan como puente entre el análisis espacial o geotecnologías (SIG, GEE) y la representación visual tridimensional, ofreciendo un producto que sintetiza la información para la toma de decisiones. De otro lado se busca facilitar la exploración y comunicación de los resultados, permitiendo mostrar el gradiente térmico no solo como un mapa plano, sino como un elemento tridimensional que se relaciona con la topografía y las infraestructuras locales.

## **7. Metodología**

### **7.1 Recopilación de datos geotérmicos**

La base de datos utilizada corresponde al conjunto F46\_GradientGeotermic\_Pozos, publicado por el Servicio Geológico Colombiano (SGC), Grupo de trabajo Geotermia, bajo licencia CC BY 4.0. Los datos se descargaron desde ArcGIS Online (metadatos oficiales disponibles). Según el resumen técnico del SGC (2020), el potencial geotérmico de Colombia.

EL grupo de Geotermia calculó a través del método volumétrico, el potencial geotérmico de Colombia a partir de la información geotermométrica de los manantiales termales registrados en el territorio nacional y, asumiendo un volumen específico de influencia de un manantial o grupo de manantiales termales (clúster), como posible reservorio. Con un área de influencia de 2 km<sup>2</sup> y un espesor de 1.5 km para cada manantial termal, estos se agruparon en un total de 165 clústeres (grupo de manantiales o manantiales termales aislados) distribuidos en 21 áreas geotérmicas y 16 departamentos, localizados dentro y fuera de las áreas geotérmicas delimitadas de manera preliminar (SGC, 2020).

Esta base concentra información geotermométrica obtenida en el territorio Colombiano, con atributos que describen la localización de pozos y manantiales, así como parámetros térmicos y de profundidad.

Figura 6. Geotermia: Mapa Gradientes Geotérmico Colombia  
Fuente: Instituto Geológico Colombiano IGC y Autor



Los datos fueron descargados en formato vectorial (shapefile) y en tabla (CSV), acompañados de su respectiva documentación y metadatos. Queda claro entonces que esta información fue creada originalmente para un estudio nacional de estimación preliminar del potencial geotérmico de Colombia, sin embargo, para el presente TFM se aplicó un filtro espacial y temático, centrando la atención en el municipio de Orito (Putumayo), en el contexto de la cuenca Caguán–Putumayo.

Los datos se descargaron desde la plataforma ArcGIS Online, cuyo metadato oficial está disponible en:

<https://www.arcgis.com/sharing/rest/content/items/bf871b71a6094ccd9979218e3440df5c/info/metadata/metadata.xml?format=default&output=html>

El área de interés (AOI) fue definida mediante un polígono “Boundary” preparado en SIG y cargado como recurso de referencia en Google Earth Engine y QGIS. Este polígono delimita la zona sobre la cual se enmascararán los análisis, garantizando que solo se trabajen los datos relevantes al contexto geográfico de Orito. Una vez aplicado el filtro espacial, se identificaron aproximadamente cien puntos de gradiente geotérmico que se encuentran dentro del AOI. Esta cifra proporciona una base sólida para el análisis, manteniendo un número suficiente de observaciones para técnicas de interpolación, modelado térmico y generación de cartografía temática.

Durante este proceso fue necesario resolver varios inconvenientes propios del trabajo con datos geotécnicos de distintos sistemas de medida. La base original incluía profundidades en pies (ft) y temperaturas registradas tanto en grados Fahrenheit como en Celsius, lo que obligó a unificar todo al Sistema Métrico Decimal (normalización), empleando metros (m) para profundidades y grados Celsius (°C) para temperaturas. En cuanto al control de calidad de los datos, también se detectaron valores nulos o inconsistentes que requirieron verificación manual, para complementar el proceso de normalización de los nombres y formatos de los campos clave (GRADIENTE, PROFUNDI\_2, TEMPERATUR) para asegurar su compatibilidad entre entornos como QGIS y Civil 3D. Estas tareas, aunque invisibles en los resultados finales, son esenciales para evitar errores en las fases de análisis y modelado.

#### 7.1.1 Alcance y localización del Area de Estudio (Orito, Putumayo)

Como se ha establecido anteriormente y el análisis se enfocó en el área de interés (AOI) se utiliza como máscara espacial en todas las etapas (SIG, GEE y CAD).

Dentro el proceso de manipulación de los datos de los gradientes, se llevaron a cabo conversiones entre distintos sistemas de coordenadas para asegurar la interoperabilidad de los datos en todas las plataformas utilizadas.



El dataset original contenía 4605 registros a nivel nacional de los cuales 194 pertenecen a la cuenca Caguán- Putumayo.

	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X
	EPARI	CUENCA	LATITUD	LONGIT	COORDENA	COORDEN	ELEVAC	ELEVACI	TEMPEF	BHT_Q	BHT_Q	PROFUI	PROFUJ	TEMPEF	GRADIENTE	GRADIE	NU
118	utumayo	Caguan-Putumayo	0.623672	-76.9997	674947.9793	560500.24	2289	697.6872	24.71156	160	71.11111	7743	2360.066	79.07363	19.660272	23.03413	Un
119	utumayo	Caguan-Putumayo	0.600181	-77.0111	673674.6258	557899.926	2141	652.5768	24.93712	84	28.88889	7868	2398.166	37.00918	1.647831	5.033874	Un
120	utumayo	Caguan-Putumayo	0.634592	-76.9856	676518.72	561708.364	1982	604.1136	25.17943	178	81.11111	7938	2419.502	89.31964	23.117017	26.50967	Un
121	utumayo	Caguan-Putumayo	0.597039	-77.0175	672963.8512	557552.453	2071	631.2408	25.0438	173	78.33333	7893	2405.786	86.48515	22.150569	25.53899	Un
411	utumayo	Caguan-Putumayo	0.606276	-76.5647	723420.3311	558549.885	903	275.2344	26.82383	200	93.33333	10573	3222.65	104.6712	20.638139	24.15632	Do
413	utumayo	Caguan-Putumayo	0.305911	-76.9149	684390.184	525315.149	297	90.5256	27.74737	159	70.55556	6268	1910.486	76.6582	22.406955	25.60125	Un
447	utumayo	Caguan-Putumayo	0.321456	-76.8667	689760.7173	527034.63	952	290.1696	26.74915	222	105.5556	10800	3291.84	117.1325	23.939925	27.45679	Do
452	utumayo	Caguan-Putumayo	0.287539	-76.912	684711.6581	523281.049	976	297.4848	26.71258	217	102.7778	10830	3300.984	114.3858	23.04319	26.55972	Do
467	utumayo	Caguan-Putumayo	0.540569	-77.0766	666369.7453	551303.262	1788	544.9824	25.47509	189	87.22222	9001	2743.505	96.75063	22.506662	25.97974	Un

Figure 7. Registro de Gradientes - datos crudos

Fuente: IGC

Tras el filtrado espacial y temático para Orito y la limpieza de atributos, se obtuvo la capa Gradiente\_Orito\_WGS84, base para la interpolación, el análisis satelital (LST/NDVI/NDWI) y el modelado 3D en CAD. EL total de registros para estudiados para el municipio de Orito es de 98 gradientes distribuidos tanto en la zona urbana como rural del municipio.

CUENCA	Count
Valle Medio del Magdalena	2329
Llanos Orientales	861
Valle Superior del Magdalena	479
Catatumbo	398
Caguan-Putumayo	194
Valle Inferior del Magdalena	137
Cordillera oriental	113
Sinú-San Jacinto	54
Guajira	17
Cesar-Rancheria	6
ANP	6
Choco	4
Uraba	3
Cauca-Patia	2
Tumaco	2

Figure 7. Registro de Gradientes

Fuente: IGC

## Datos normalizados, procesados y listos para realizar análisis con las herramientas geotecnológicas y GEE

fid	UWI	NOMBRE_DEL	DEPARTAMEN	CUENCA	LATITUD	LONGITUD	ELEVACION	TEMPERATUR	BHT_OC	PROFUNDI_2	TEMPERAT_1	GRADIENT_1	AÑO_DE_AC	OBSERVACION
117	CARI0001	CARIBE-1	Putumayo	Caguan-Putum...	0.623672	-76.999694	697.6872	24.711564	71.111111	2360.0664	79.073632	23.034126	2008	
118	CARI0002	CARIBE-2	Putumayo	Caguan-Putum...	0.600181	-77.011106	652.5768	24.937116	28.888889	2398.1664	37.009183	5.033874	2008	
119	CARI0003	CARIBE-3	Putumayo	Caguan-Putum...	0.634592	-76.985608	604.1136	25.179432	81.111111	2419.5024	89.319638	26.509668	2008	
120	CARI0004	CARIBE-4	Putumayo	Caguan-Putum...	0.597039	-77.017481	631.2408	25.043796	78.333333	2405.7864	86.48515	25.53899	2008	
595	CONG0001	CONGA-1	Putumayo	Caguan-Putum...	0.652879	-76.936589	540.1056	25.499472	81.666667	2427.1224	89.906681	26.536449	2008	Este pozo tiene ...
1154	CLDR0001	CALDERO-1	Putumayo	Caguan-Putum...	0.725183	-76.908372	378.8664	26.305668	87.777778	2255.52	95.306459	30.591966	2008	
2470	ORIT0001S	ORITO SUR-1	Putumayo	Caguan-Putum...	0.568547	-76.894417	409	26.155	86.666667	2764.2312	96.277648	25.367866	2008	
2471	ORIT0010	ORITO-10	Putumayo	Caguan-Putum...	0.713497	-76.904483	405.6888	26.171556	71.111111	2002.2312	77.590463	25.680804	2008	
2472	ORIT0100	ORITO-100	Putumayo	Caguan-Putum...	0.681961	-76.878753	350.2152	26.448924	46.111111	763.524	48.01076	28.239893	2008	El pozo tiene 3 ...
2473	ORIT0101	ORITO-101	Putumayo	Caguan-Putum...	0.686281	-76.873475	327.0504	26.564748	47.777778	815.6448	49.838382	28.534031	2008	El pozo tiene 3 ...

Figure 7. Registro de Gradientes - datos normalizados Fuente: Autor

### 7.2 Procesamiento de imágenes satelitales

La percepción remota es un agrupamiento de técnicas de las cuales se obtiene información sobre las propiedades físicas de ciertas superficies y los elementos que componen su entorno.

Generalmente, este proceso se hace a grandes distancias, de lo que se deduce no hay contacto físico con estos elementos.

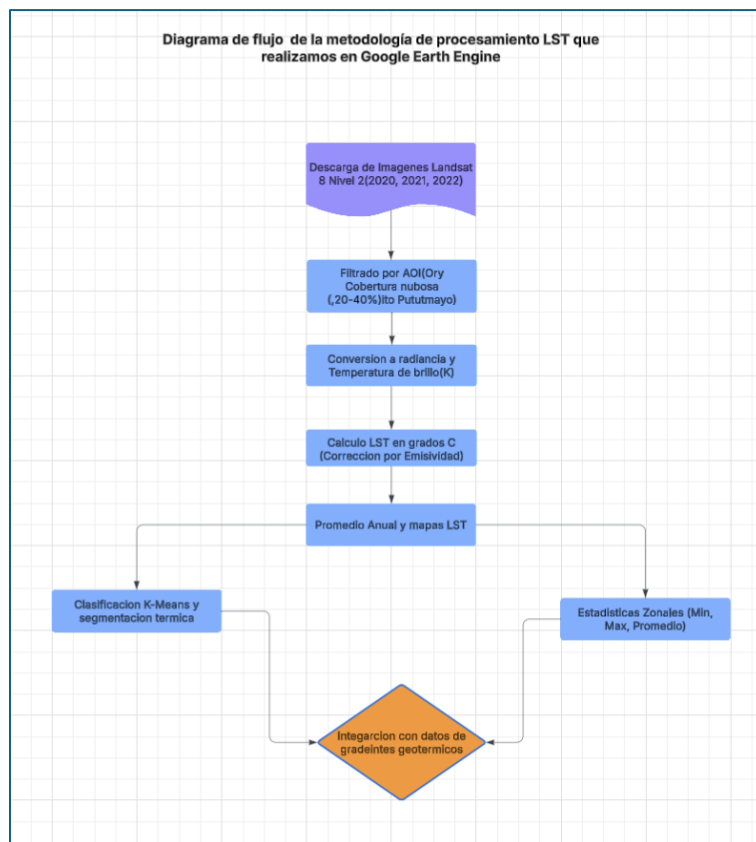
En el contexto de este trabajo, los productos satelitales estándar de Landsat 8, generados por el Centro EROS del Servicio Geológico de los Estados Unidos (USGS), constituyen una fuente primaria para la estimación de la temperatura superficial terrestre (LST), variable clave en el análisis de gradientes geotérmicos. Estos productos contienen valores numéricos digitales (DN) calibrados, derivados de la información multiespectral captada por el Operational Land Imager (OLI) y el Thermal Infrared Sensor (TIRS). Los datos se presentan en formato de enteros sin signo de 16 bits y, a través de los coeficientes de calibración radiométrica incluidos en el archivo de metadatos (MTL), es posible convertirlos en parámetros físicos como la reflectancia o la radiancia en la parte superior de la atmósfera (TOA).

El archivo MTL también integra las constantes térmicas necesarias para transformar las bandas TIRS en temperatura de brillo, lo que permite aplicar algoritmos de estimación de la temperatura superficial. Esta última resulta esencial para identificar variaciones térmicas en superficie que, combinadas con mediciones directas de gradientes geotérmicos, facilitan el análisis espacial de zonas con potencial de aprovechamiento energético (USGS, 2016).

### 7.2.1 Calculo de LST en Google Earth Engine

La Temperatura Superficial Terrestre (LST, por sus siglas en inglés) representa la temperatura física de la superficie del terreno. Esta es una medida del calentamiento directo de la superficie terrestre, donde los rayos del sol son absorbidos y reemitidos. Se puede considerar como una representación del balance energético entre la radiación solar entrante, la emisividad y los procesos de intercambio de calor con la atmósfera y el subsuelo. La medición de la LST resulta de gran relevancia en estudios de geotermia superficial, ya que las variaciones en la LST pueden ser un indicador de la existencia de anomalías térmicas asociadas a fenómenos geotérmicos, así como cambios ambientales o de uso del suelo.

Figure 8 Metodología de Procesamiento LST con GEE Engine Fuente: Autor



Para poder realizar el cálculo, se procede a determinar el área de interés (AOI), lo cual consiste en un polígono cuadrado de 10×10 km, centrado en el municipio de Orito (Putumayo), en

coordenadas geográficas WGS84 (EPSG:4326). Este AOI sirvió como máscara espacial para filtrar todas las imágenes.

```
LST_Landsat_Orito_2022
1 // -----
2 // 1. DEFINIR ÁREA CUADRADA DE ORITO (10kmx10 km)
3 // -----
4 var orito = ee.Geometry.Rectangle({
5   coords: [-77.05892, 0.56117, -76.82375, 0.73969],
6   geodesic: false
7 });
8
9 Map.centerObject(orito, 11);
10
11 var areaInteres = ee.FeatureCollection([
12   ee.Feature(
13     ee.Geometry.Polygon([
14       [
15         [-77.05892, 0.56117],
16         [-76.82375, 0.56117],
17         [-76.82375, 0.73969],
18         [-77.05892, 0.73969],
19         [-77.05892, 0.56117]
20       ]
21     )
22   )
23 ]);
24
25 Map.addLayer(
26   areaInteres.style({
27     color: 'red',
28     fillColor: '00000000', // sin relleno
29     width: 2
30   }),
31   {},
32   'Área de Interés'
33 );
34
35 var municipio = ee.FeatureCollection('projects/ee-frankcortes/assets/Municipio_Orito_4326WGS84');
36
37 Map.addLayer(
38   municipio.style({
39     color: 'blue',
40     fillColor: '00000000', // sin relleno
41     width: 2
42   }),
43   {},
44   'Limite Orito'
45 );
```

La Temperatura Superficial Terrestre (LST, por sus siglas en inglés) representa la temperatura física de la superficie del terreno, determinada por el balance energético entre la radiación solar entrante, las propiedades radiactivas de la superficie (emisividad) y los procesos de intercambio de calor con la atmósfera y el subsuelo. Ya hemos mencionado que su medición resulta de gran relevancia en estudios de geotermia superficial, ya que las variaciones en la LST pueden reflejar anomalías térmicas asociadas a fenómenos geotérmicos, así como cambios ambientales o de uso del suelo.

En el ámbito de la teledetección, la LST se obtiene mediante sensores térmicos embarcados en satélites, como el Operational Land Imager (OLI) y el Thermal Infrared Sensor (TIRS) a bordo de Landsat 8. Estos sensores captan la radiancia emitida en el rango del infrarrojo térmico (10–12  $\mu\text{m}$ ), que se transforma en temperatura a partir de la ley de Planck y de la relación existente entre radiancia y temperatura de brillo.

La combinación de bandas para Landsat 8 tiene dos sensores principales, el OLI y el TIRS, para capturar datos espectrales. El OLI tiene 9 bandas que cubren el espectro visible y el infrarrojo cercano, mientras que el TIRS tiene 2 bandas que operan en el infrarrojo de onda larga. Las bandas se combinan para crear imágenes con diferentes características, como el color, la vegetación, el cultivo, y más. Por ejemplo, las bandas 2, 3 y 4 (filtros azul, verde y rojo respectivamente) se

combinan para crear imágenes RGB normales de luz visible. La banda 8 es la pancromática, que recoge el mayor número posible de espectros en un solo canal, lo que le permite obtener imágenes más nítidas (<https://landsat.gsfc.nasa.gov/satellites/landsat-8/landsat-8-bands/>).

Landsat-7 ETM+ Bands (µm)			Landsat-8 OLI and TIRS Bands (µm)		
			30 m Coastal/Aerosol	0.435 - 0.451	Band 1
Band 1	30 m Blue	0.441 - 0.514	30 m Blue	0.452 - 0.512	Band 2
Band 2	30 m Green	0.519 - 0.601	30 m Green	0.533 - 0.590	Band 3
Band 3	30 m Red	0.631 - 0.692	30 m Red	0.636 - 0.673	Band 4
Band 4	30 m NIR	0.772 - 0.898	30 m NIR	0.851 - 0.879	Band 5
Band 5	30 m SWIR-1	1.547 - 1.749	30 m SWIR-1	1.566 - 1.651	Band 6
Band 6	60 m TIR	10.31 - 12.36	100 m TIR-1	10.60 - 11.19	Band 10
			100 m TIR-2	11.50 - 12.51	Band 11
Band 7	30 m SWIR-2	2.064 - 2.345	30 m SWIR-2	2.107 - 2.294	Band 7
Band 8	15 m Pan	0.515 - 0.896	15 m Pan	0.503 - 0.676	Band 8
			30 m Cirrus	1.363 - 1.384	Band 9

Table courtesy of B. Markham (July 2013). + PDF version

Tabla 1. Bandas Landsat 8 Autor: B. Markham(Julio 2013)

El cálculo de la LST en Google Earth Engine (GEE) se llevó a cabo en los siguientes pasos:

- Se cargaron y se procesaron las imágenes Landsat 8 Nivel 2 para los años 2020, 2022 y 2024 respectivamente, aplicando filtros por cobertura nubosa (<20–40%) y recortando la información al Área de Interés (AOI) correspondiente al municipio de Orito, Putumayo.

```
// 3. COLECCIÓN LANDSAT 2020 CON FILTRO DE NUBES
var l8_2020 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
  .filterBounds(orito)
  .filterDate('2020-01-01', '2020-12-31')
  .filter(ee.Filter.lt('CLOUD_COVER', 20))
  .map(toLST);
```

```
// -----
// 2. CARGAR LANDSAT 8 NIVEL 2 - AÑO 2021
// -----
var l8 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
  .filterBounds(orito)
  .filterDate('2021-01-01', '2021-12-31')
  .filter(ee.Filter.lt('CLOUD_COVER', 40)); // Subimos el límite de nubes
```

```
// -----
// 2. CARGAR LANDSAT 8 NIVEL 2 - AÑO 2022
// -----
var l8 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
  .filterBounds(orito)
  .filterDate('2022-01-01', '2022-12-31')
  .filter(ee.Filter.lt('CLOUD_COVER', 20));
```

Tabla 2 — Parámetros de procesamiento por año Fuente: Autor

Ano	Satélite(s)	Cloud_Cover	AOI/CRS	Composición	QA (solo stats)	Máscara agua (stats tierra)
2020	Landsat 8 (L2SP)	≤ 20 %	25×25 km — EPSG:4326	Media + respaldo cálido + unmask	QA_PIXEL bits 3/4=0	JRC >50% excluida
2022	Landsat 8/9 (L2SP)	≤ 20 %	25×23 km — EPSG:4326	Media + respaldo cálido + unmask	QA_PIXEL bits 3/4=0	JRC >50% excluida
2024	Landsat 8/9 (L2SP)	≤ 40 %	25×23 km — EPSG:4326	Media + respaldo cálido + unmask	QA_PIXEL bits 3/4=0	JRC >50% excluida

- Conversión de valores digitales (DN) a radiancia espectral, utilizando los factores de calibración (ganancia y sesgo) incluidos en los metadatos del producto satelital.
- Se realiza la transformación a temperatura de brillo en Kelvin, aplicando la ecuación inversa de la ley de Planck. La banda térmica ST\_B10 se convirtió a Kelvin utilizando los factores de escala y desplazamiento provistos por USGS:

$$BT(k) = (ST_{10} \times 0.00341802) + 149.0$$

```
// -----
// 3. CONVERTIR ST_B10 A TEMPERATURA EN °C
// -----
var toLST = function(img) {
  var tempK = img.select('ST_B10')
    .multiply(0.00341802)
    .add(149.0); // radiancia → Kelvin


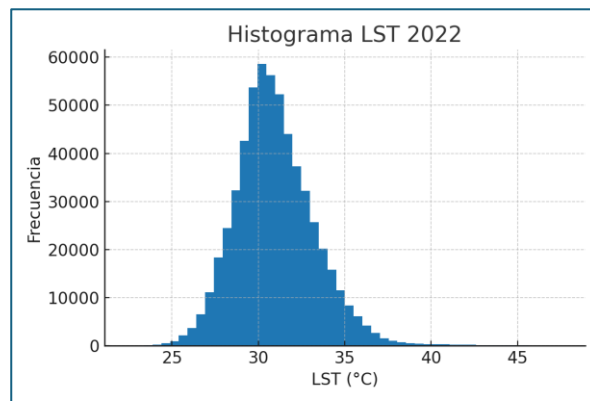

  var tempC = tempK.subtract(273.15).rename('LST_C'); // Kelvin → Celsius
  return tempC.copyProperties(img, img.propertyNames());
};
var lstCollection = l8.map(toLST);
```

Se realizó la corrección por emisividad superficial y conversión a grados Celsius (°C), de esta manera se logró determinar la LST final. La LST fue el resultado de la sustracción de 273.15 a la BT, asumiendo una emisividad como ( $e = 1$ ). Esta aproximación es suficiente para los trabajos o estudios comparativos, aunque puede subestimar o sobrestimar ligeramente el valor absoluto ( $\pm 1-3$  °C).

- La metodología también incluyó el procesamiento y visualización del cálculo de la LST media anual para cada año de estudio.

```
// -----
// 4. CALCULAR PROMEDIO ANUAL DE LST
// -----
var lstMean = lstCollection.mean().clip(orito);
```

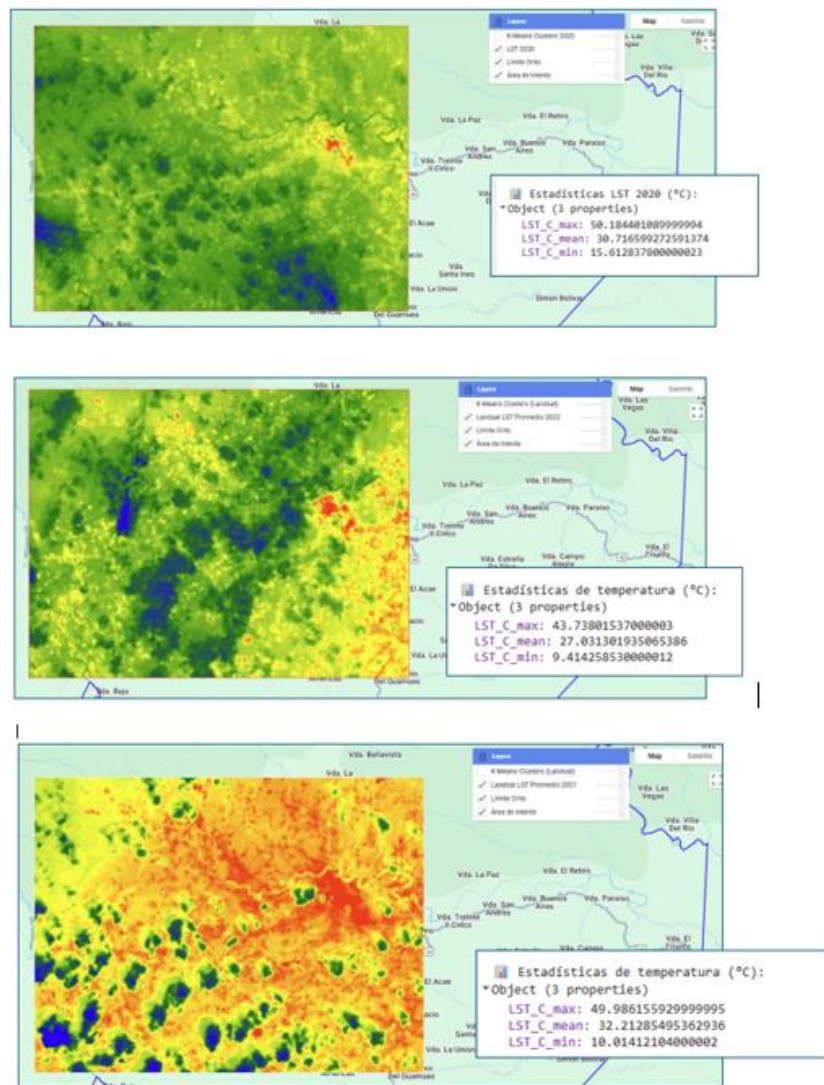
Figura 9. LST2020, 2022 y 2024 – Orito GEE Engine Fuente: Autor



- Generación de mapas temáticos en escala de color térmica (azul-rojo).

```
// -----  
// 5. VISUALIZAR MAPA TÉRMICO  
// -----  
Map.addLayer(lstMean, {  
  min: 15,  
  max: 40,  
  palette: ['blue', 'green', 'yellow', 'red']  
}, 'Landsat LST Promedio 2022');  
  
// -----  
// 6. EXPORTAR MAPA TÉRMICO A GOOGLE DRIVE  
// -----  
Export.image.toDrive({  
  image: lstMean,  
  description: 'LST_Landsat_Orito_2022',  
  folder: 'EarthEngine_Exports',  
  fileNamePrefix: 'LST_Landsat_Orito_2022',  
  region: orito,  
  scale: 30,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```

Figura 10. LST2020 – Orito GEE Engine Fuente: Autor



Se procedió a la clasificación no supervisada K-means para segmentar patrones térmicos. A través del algoritmo de agrupamiento K-means (*clustering*) se agruparon los píxeles en función de su similitud de valores, en este caso, la temperatura superficial. Se definieron 3 clases (clusters), que en la práctica representaron rangos térmicos (temperaturas bajas, medias y altas dentro del área de estudio), esta agrupación se considera como no supervisado porque no se le dijo al algoritmo cuáles eran las clases de antemano, sino que el algoritmo detecta las agrupaciones más naturales en los datos.

```
// -----  
// 7. APLICAR K-MEANS CLUSTERING  
// -----  
var training = lstMean.sample({  
  region: orito,  
  scale: 30,  
  numPixels: 1000,  
  geometries: true  
});  
  
var clusterer = ee.Clusterer.wekaKMeans(3).train(training);  
var result = lstMean.cluster(clusterer);
```

A través del código también se logró obtener estadísticas zonales (mínimo, máximo, promedio) para evaluar la variabilidad térmica interanual.

```
// 6. CALCULAR ESTADÍSTICAS  
var stats2020 = lst2020.reduceRegion({  
  reducer: ee.Reducer.minMax().combine({  
    reducer2: ee.Reducer.mean(),  
    sharedInputs: true  
  }),  
  geometry: orito,  
  scale: 30,  
  maxPixels: 1e13  
});  
print('📊 Estadísticas LST 2020 (°C):', stats2020);
```

Esta segmentación nos permite identificar patrones espaciales de calor dentro de Orito. Esto fue muy útil para comparar la distribución espacial de las temperaturas entre distintos años y ver si las zonas más cálidas o frías cambian de extensión o ubicación. Además, ayudo a visualizar de forma intuitiva las diferencias térmicas en mapas temáticos, incluso para audiencias no técnicas.

```
// -----  
// 8. VISUALIZAR CLUSTERING  
// -----  
Map.addLayer(result.randomVisualizer(), {}, 'K-Means Clusters (Landsat)');
```

El procesamiento de las imágenes Landsat 8 Nivel 2 para los años 2020, 2021 y 2022, se pudo generar comparativos de temperatura superficial terrestre (LST) del área de Orito. La metodología se ejecutó manteniendo idénticos parámetros de selección y procesamiento para garantizar la comparabilidad interanual. Los resultados muestran variaciones tanto en los valores absolutos de temperatura como en la distribución espacial de las zonas más cálidas y frías. En 2020 se

detectaron máximos de hasta 50,18 °C y mínimos cercanos a 15,61 °C, con áreas calientes concentradas principalmente en superficies sin cobertura vegetal y suelos expuestos.

En 2022, los valores máximos alcanzaron 49,96 °C y los mínimos 10,41 °C, observándose una mayor extensión de áreas con temperaturas altas, probablemente asociadas a condiciones de menor humedad superficial y menor nubosidad en las escenas seleccionadas. En 2022, el máximo registrado fue de 43,73 °C y el mínimo de 9,41 °C, con un patrón más disperso de puntos calientes respecto a años anteriores. Hay valores más altos que lo esperado para Orito si pensamos en temperatura ambiente, pero hay que recordar que el LST satelital mide temperatura superficial instantánea, y en zonas de suelo desnudo, techos metálicos o rocas expuestas bajo radiación intensa, puede fácilmente superar los 45 °C, incluso en regiones húmedas.

Dentro de las posibles causas de las diferencias encontradas en LST entre años pueden atribuirse a varios factores tales como:

- Condiciones climáticas y meteorológicas. Las variaciones en precipitación, nubosidad, radiación solar y humedad relativa influyen directamente en la temperatura de la superficie. Años más secos o con periodos prolongados de insolación tienden a presentar valores LST más elevados.
- Fenología y cobertura vegetal: Está claramente establecido que cambios en la densidad y tipo de vegetación modifican la emisividad y la capacidad de enfriamiento por evapotranspiración, generando contrastes térmicos detectables en los mapas.
- Cambios en el uso del suelo: La deforestación, expansión urbana o actividades agrícolas intensivas pueden aumentar la absorción de calor y reducir la disipación térmica. En Orito, la problemática ambiental por el tema de la tala para el establecimiento de minería ilegal y de cultivos ilícitos es un gran problema para las autoridades locales y ambientales del país. Cientos de hectáreas se pierden anualmente debido a estos problemas en la zona de estudio.
- Condiciones de adquisición de las imágenes: aunque se aplicaron filtros estrictos de nubosidad y rango temporal, ligeras diferencias en hora de paso del satélite o en el ángulo solar pueden influir en las temperaturas registradas. En los años 2020 y 2022 se estableció un umbral máximo de nubosidad del 20% ( $CLOUD\_COVER < 20$ ), mientras que en 2021 se amplió a un 40% ( $CLOUD\_COVER < 40$ ) debido a la limitada disponibilidad de escenas libres de nubes, manteniendo siempre una revisión visual de las imágenes seleccionadas. Además, la LST de cada año se obtuvo a partir del promedio de todas las escenas válidas, lo que reduce el impacto de nubes residuales o sombras, cuyo efecto típico es disminuir localmente la temperatura estimada.

Este enfoque garantiza que los valores máximos registrados no estén inflados por artefactos atmosféricos y que las variaciones interanuales observadas correspondan a cambios reales en las condiciones de superficie, preservando la comparabilidad y solidez del análisis. Los filtros

aplicados y el cálculo de promedios anuales aseguran que los resultados conserven solidez y comparabilidad, por lo que se puede deducir inicialmente, que no habría indicios de que la nubosidad comprometa la credibilidad del análisis.

Estas variaciones interanuales sugieren que la dinámica térmica superficial de Orito está condicionada por una combinación de factores naturales y antrópicos. La consistencia metodológica aplicada asegura que las diferencias observadas no se deben a errores de procesamiento, sino a cambios reales en las condiciones de la superficie y la atmósfera. Este análisis permite de forma aproximada reconocer patrones recurrentes o anomalías térmicas que puedan estar asociadas a fenómenos geotérmicos y establecer hipótesis sobre la interacción entre procesos superficiales (vegetación, uso del suelo) y subsuperficiales (gradientes geotérmicos).

Se puede concluir entonces que la serie temporal de LST generada no solo proporciona un diagnóstico térmico detallado de Orito para tres años clave, sino que también permite interpretar tendencias y cambios que fortalecen el análisis geotérmico general de nuestro estudio.

La importancia de esta etapa dentro del TFM radica en que los productos generados permiten:

- Identificar y caracterizar anomalías térmicas superficiales potencialmente asociadas con actividad geotérmica.
- Evaluar la variabilidad temporal de la temperatura superficial en un período de tres años.
- Disponer de insumos listos para su integración con datos de gradiente geotérmico in situ, posibilitando análisis correlacionales entre superficie y subsuelo.
- El cálculo de LST en GEE pudo abordarse siguiendo la formulación estándar, que incluye la corrección por emisividad y efectos atmosféricos. Sin embargo, en este trabajo solo se adoptó una metodología simplificada, ampliamente utilizada en análisis exploratorios y comparativos, cuyo objetivo principal no es obtener valores absolutos de temperatura con precisión radiométrica, sino identificar patrones espaciales y variaciones temporales.

## 7.2. Clasificación no supervisada K-means en Google Earth Engine

El algoritmo K-means es un algoritmo de agrupamiento no supervisado que clasifica los píxeles en un número fijo de grupos (en nuestro trabajo, 3) en función de la similitud de sus valores de temperatura superficial (LST). Este algoritmo K-means clustering se implementó en Google Earth Engine con WekaKMeans. La versión de GEE (`ee.Clusterer.wekaKMeans`) viene de la librería Weka integrada, que aplica el método iterativo de K-means estándar:

- Elige aleatoriamente  $k$  centroides iniciales (aquí  $k = 3$ ).
- Elige  $k$  centroides de forma aleatoria




Figura 16. k-means en la inicialización

Fuente: <https://developers.google.com/machine-learning/clustering/kmeans>

- Asigna cada píxel al centroide más cercano según su valor LST.




Figura 17. Clústeres iniciales

Fuente: <https://developers.google.com/machine-learning/clustering/kmeans>

- Recalcula los centroides como el promedio de los píxeles asignados.




Figura 18. Centroides recalculados

Fuente: <https://developers.google.com/machine-learning/clustering/kmeans>

---

- Repite el proceso hasta que las asignaciones se estabilizan.




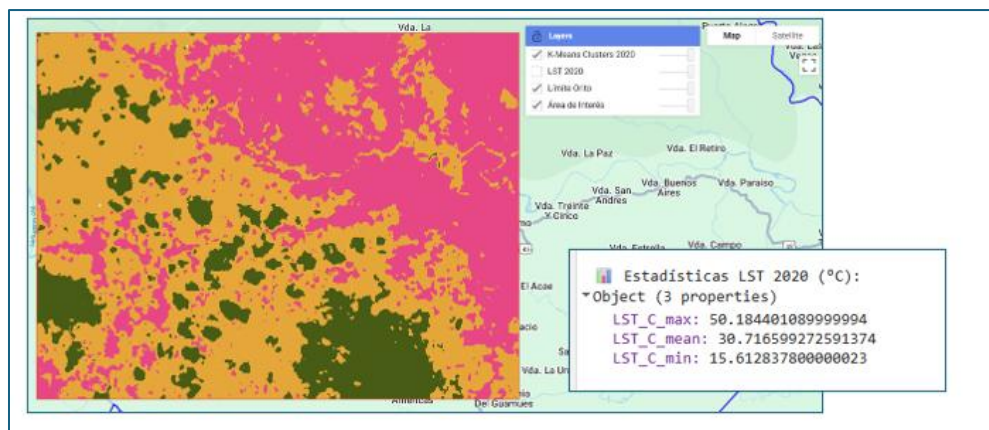
Figura 11. Conglomerados después de la reasignación

Fuente: <https://developers.google.com/machine-learning/clustering/kmeans>


A través de este algoritmo que generó las zonas de color en las imágenes K-means y cada color representa una de las tres clases térmicas identificadas.

La clasificación no supervisada K-means aplicada sobre las imágenes de temperatura superficial terrestre (LST) permitió segmentar el área de Orito en tres clases térmicas distintas para los años 2020, 2022 y 2024. Cada clase se representó con un color: tonos verdes para las zonas más frías, tonos naranjas para las temperaturas intermedias y tonos fucsia para las más cálidas.

Figura 12. cálculo de K – Means Landsat 2020 - Orito GEE Engine Fuente: Autor

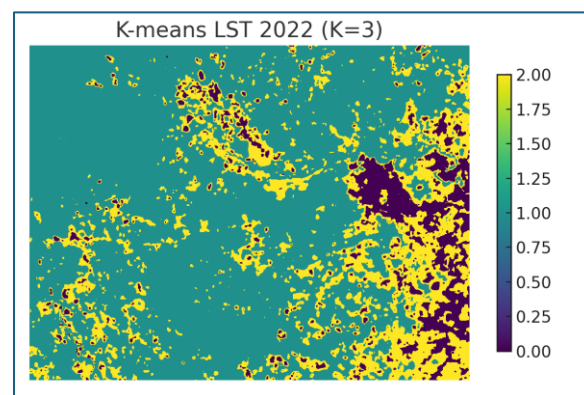
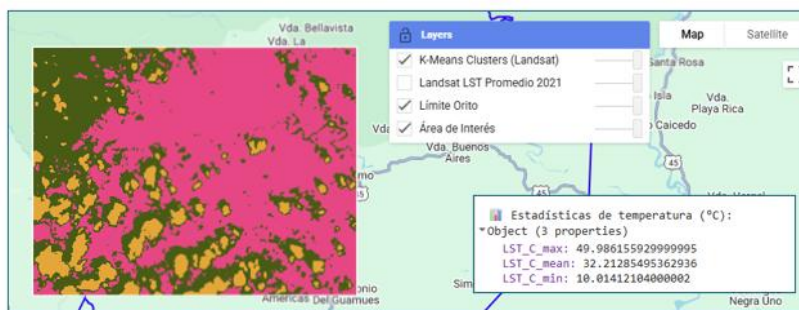


En 2020, las áreas cálidas se concentraron principalmente en la porción centro-oriental y sur del municipio, mientras que las zonas frías se localizaron en sectores dispersos, asociados a coberturas vegetales densas o suelos con alta humedad. Las zonas intermedias formaron un cinturón de transición que separaba ambos extremos térmicos.



En 2022, el escenario se revirtió parcialmente, con una reducción de la superficie ocupada por las clases cálidas y un incremento notable de las zonas frías, que recuperaron presencia especialmente en el sector occidental y noroccidental. Las temperaturas intermedias se distribuyeron de manera más equilibrada, generando un patrón menos fragmentado que en los años anteriores.

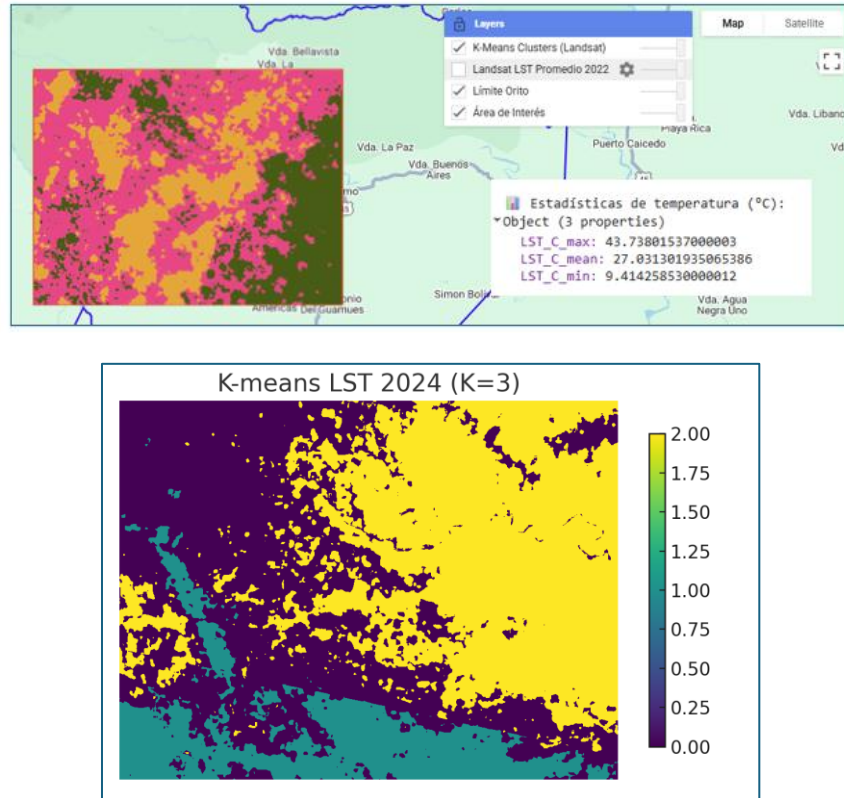
Figura 13. cálculo de K – Means Landsat 2022 - Orito GEE Engine Fuente: Autor



Este cambio sugiere que hay condiciones superficiales más secas y homogéneas, lo que de alguna manera favorece una mayor continuidad espacial de las temperaturas elevadas.

En 2024, el patrón cambió y se evidencia una expansión significativa de las áreas clasificadas como cálidas que cubrieron gran parte del centro y norte del área de estudio. Las zonas frías se redujeron, quedando relegadas a pequeños núcleos aislados.

Figure 14. cálculo de K – Means Landsat 2024 - Orito GEE Engine Fuente: Autor



La comparación para varios años de los mapas K-means realizados en este trabajo, podría evidenciar que la distribución térmica de las clases responde a variaciones climáticas y de cobertura del suelo, es decir, esta no es estática, sino que permite segmentar de forma más objetiva el área de estudio del municipio de Orito, en zonas térmicamente homogéneas, sin necesidad de imponer rangos de temperatura predeterminados.

La ocurrencia de ciertas áreas cálidas entre años podría indicar zonas con propiedades superficiales y subsuperficiales favorables en teoría a la acumulación de calor, mientras que las áreas frías mostrarían una mayor sensibilidad a las condiciones meteorológicas estacionales.

Tabla 2 — Estadísticos LST por año (desde GeoTIFF) Fuente: Autor

Year	Count	Min	p5	p50	Mean	p95	Max	Std
2020	578771	15.61284	24.81244	31.00076	30.7155	35.16391	50.1844	3.22264
2022	578771	22.36274	27.54583	30.76082	30.97393	34.9643	47.65404	2.324558
2024	578771	11.03867	22.3724	29.50336	29.0921	34.20656	49.12217	3.783042

Finalmente, al agrupar los píxeles en tres clases térmicas, facilitó la identificación visual y estadística de regiones con mayor o menor acumulación de calor superficial y de esta manera se pueden correlacionar estos patrones con variables como uso del suelo, cobertura vegetal o presencia de manifestaciones geotérmicas. Esta información puede ser un gran complemento para priorizar zonas en estudios posteriores y para la correlación con datos de gradiente térmico obtenidos en campo.

Tabla 3— Distribución K-means por año (píxeles y %) Fuente: Autor

Year	Cluster	Pixels	Pct
2020	0	133515	23.06759341
2020	1	60548	10.46097177
2020	2	384736	66.47143482
2022	0	45328	7.83138879
2022	1	412544	71.27586606
2022	2	120927	20.89274515
2024	0	250341	43.25180244
2024	1	82690	14.28647942
2024	2	245768	42.46171814

Tabla 4 — K-means por rango térmico (ordenado por LST media) Fuente: Autor

Year	Cluster	Pixels	Pct
2020	0	133515	23.06759
2020	1	60548	10.46097
2020	2	384736	66.47143
2022	0	45328	7.831389
2022	1	412544	71.27587
2022	2	120927	20.89275
2024	0	250341	43.2518
2024	1	82690	14.28648
2024	2	245768	42.46172

En los posteriores apartados se realizará un proceso diferente de análisis de la temperatura superficial de Orito desde el punto de vista del análisis espacial, haciendo uso de las herramientas geotecnológicas y de procesamiento de imágenes del software Arc Gis Pro 3.4. A través de las múltiples herramientas de procesamiento y cálculo se consigue analizar con más detalle la calidad

de la información hasta ahora analizada. El análisis de la relación entre la temperatura de la superficie terrestre y las características del paisaje se puede realizar eficazmente con índices espectrales en Google Earth Engine (Roya y Bari, 2022).

Los índices espectrales como el de la superficie terrestre (LST), el índice de diferencia normalizada de vegetación (NDVI) y el índice de diferencia normalizada de áreas construidas (NDBI) se utilizan para calcular los diferentes comportamientos que ocurren sobre la superficie terrestre, su vegetación y las áreas construidas. Está claro que cada uno de ellos funciona de forma independiente y se puede ver la diferencia a través de imágenes de satélite.

### 7.3 Adquisición de Imágenes e Calculo de índices Espectrales

Los índices espectrales son combinaciones matemáticas de valores de reflectancia en diferentes bandas del espectro electromagnético, diseñadas para resaltar o cuantificar características específicas de la superficie terrestre, como la vegetación, el agua o la temperatura. Estos índices permiten simplificar la interpretación de imágenes satelitales y facilitar su análisis temático (Pettorelli et al., 2005).




Figura 15. Bandas Espectrales de las imágenes Landsat Fuente: NASA

Los índices espectrales son herramientas importantes para el preprocesamiento de las imágenes Landsat 8 y la estimación de la temperatura superficial terrestre (LST).

Las imágenes Landsat permiten generar una amplia gama de índices espectrales, tales como:

- NDVI (Normalized Difference Vegetation Index)
- EVI (Enhanced Vegetation Index)
- SAVI (Soil Adjusted Vegetation Index)
- SAVI (Modified Soil-Adjusted Vegetation Index)
- NDMI (Normalized Difference Moisture Index)

En el cálculo de los índices espectrales se utilizaron escenas Landsat 8 y 9 Collection 2 Level-2 (L2SP), descargadas desde el portal del USGS (United States Geological Survey), a partir de las cuales se calcularon tres índices espectrales principales: NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index) y NDMI (Normalized Difference Moisture Index). El objetivo de este proceso era mejorar la estimación de la temperatura superficial terrestre (LST) con GEE Engine y su vinculación con gradientes geotérmicos. Si hay una relación, esto podría ser una gran ayuda para la visualización de las islas de calor, la existencia de anomalías y el flujo de calor en la zona de Orito.

Los índices espectrales aportan información directa sobre la vegetación, la humedad superficial y la emisividad, variables críticas para la correcta derivación de la temperatura superficial terrestre a partir de datos Landsat 8 (Sobrino et al., 2004). Estos índices, obtenidos mediante combinaciones matemáticas de reflectancias en bandas específicas, permiten derivar información biofísica y térmica relevante. Entre ellos, el NDVI (Normalized Difference Vegetation Index) es fundamental para estimar la emisividad de la superficie, al diferenciar la cobertura vegetal de otras coberturas, mientras que el NDWI (Normalized Difference Water Index) se emplea para identificar la presencia de humedad superficial y cuerpos de agua que pueden influir en la respuesta térmica. Ambos índices se calculan a partir de las bandas multiespectrales del sensor OLI, y su integración con las bandas térmicas del sensor TIRS permite obtener valores de LST más precisos.

Como se mencionó anteriormente, se parte de la premisa de que la información inferida de los índices espectrales calculados, unida a los datos de gradiente geotérmico suministrados por el Servicio Geológico Colombiano (SGC), en teoría no serán de gran ayuda para la identificación de zonas con variaciones térmicas significativas, potencialmente asociadas a áreas de interés del municipio de Orito en cuanto al aprovechamiento geotérmico en el futuro.

Tabla 5. índices Espectrales Landsat

Fuente: Autor

Índice	Bandas Landsat 8 (OLI/TIRS)	Aplicación en el TFM
NDVI (Normalized Difference Vegetation Index)	B4 (Rojo), B5 (Infrarrojo cercano)	Estimación de la emisividad a partir de la cobertura vegetal, necesaria para el cálculo de LST.
NDWI (Normalized Difference Water Index)	B3 (Verde), B5 (Infrarrojo cercano)	Identificación de cuerpos de agua y humedad superficial que afectan la respuesta térmica.
NDMI (Normalized Difference Moisture Index)	B5 (Infrarrojo cercano), B6 (Infrarrojo de onda corta 1)	Evaluación del contenido de humedad en vegetación y suelo para ajustar la estimación térmica.

Las fórmulas definidas para los índices Landsat están normalizadas y utilizan reflectancia de superficie corregida radiométricamente.

### 7.3.1 Análisis satelital y geoespacial en Arc GIS Pro 3.4

El análisis metodológico aplicado en esta investigación se desarrolló en ArcGIS Pro 3.4, complementando los productos de temperatura superficial terrestre (LST) previamente calculados en Google Earth Engine (GEE) a partir de las imágenes Landsat Collection 2 Level-2. En esta fase se procedió al control de calidad de las imágenes y se generaron índices espectrales, anomalías térmicas, análisis de correlación.

La mayor parte del proyecto se realizó en ArcGIS Pro, organizando un flujo reproducible por año (2020, 2022 y 2024), pero también se utilizaron PyCharm y QGIS. El sistema de referencia del proyecto se fijó en UTM WGS84 Zona 18N (EPSG:32618) Proyección: UTM (Universal Transverse Mercator) para asegurar la coherencia espacial con la cartografía oficial y permitir análisis comparables entre años. Algunas de las capas tuvieron que ser reproyectadas y alineadas a EPSG:32618.

Con el fin de estandarizar el flujo de trabajo y garantizar la reproducibilidad de los resultados, se empleó la herramienta Model Builder de ArcGIS Pro. El uso de ModelBuilder garantizó la homogeneidad entre escenas y fechas. Todos los productos se gestionan dentro de una Geodatabase (GDB), lo que asegura la consistencia espacial, la nomenclatura y la trazabilidad de los resultados. Este procedimiento asegura la reproducibilidad de la metodología en diferentes entornos de software, aunque en el presente estudio se usa GEE Engine por su eficiencia en el manejo de grandes volúmenes de datos y su consistencia en series temporales; el uso de otras geotecnologías fue vital para complementar el mismo.

### 7.3.1 Metodología aplicada en el análisis de índices espectrales: caso Orito.

La metodología aplicada en este trabajo integra teledetección con SIG para derivar y comparar, en múltiples fechas, la Temperatura Superficial Terrestre (LST) y tres índices espectrales (NDVI, NDWI, NDBI) sobre el municipio de Orito (Putumayo).

El procesamiento de índices espectrales como NDVI, NDBI, NDWI a partir de imágenes de satélite exige una cadena de preprocesamiento rigurosa que garantice calidad radiométrica, comparabilidad temporal y trazabilidad. Este procedimiento asegura que los resultados NDVI, NDBI y NDWI sean limpios, es decir, sin datos nulos que entorpecerían o sesgarían los resultados. Las escenas resultantes no deben salir con valores imposibles y habilitadas para ser comparadas entre escenas y fechas. El flujo metodológico se usó para el espacio temporal de 2020 y se estableció como flujo de referencia que luego sería replicado en los años posteriores.

El procedimiento implicó varias actividades de preproceso

- Descargar las imágenes Landsat 8 Collection 2 Level-2 usando GEE Engine y descarga de imágenes Landsat 8-9 L2SP (USGS) con las bandas SR\_B3 (GREEN), SR\_B4 (RED), SR\_B5 (NIR), SR\_B6 (SWIR1) y ST\_B10
- Crear la máscara con QA\_PIXEL (nube/sombra/cirros/nieve) a nivel de píxel. El uso de QA\_PIXEL ayudó a filtrar las nubes, sombras, nubes y nieve por píxel, impidiendo que estas coberturas no deseadas degraden los valores reales de los índices. Aunque al descargar las imágenes de GEE Engine se haya aplicado un filtro de Cloud Cover (20% y 40% en nuestro caso), ese filtro es a nivel de escena y no garantiza cielos limpios en todos los píxeles.
- Recorte (Clip Raster) de todas las bandas al polígono AOI\_Orito.
- Generación de la máscara binaria (valid\_2020) a partir de QA\_PIXEL, filtrando nubes, cirros, sombras y nieve mediante bits de calidad. Se usó BitwiseAnd == 0 para eliminar los factores de distorsión mencionados, quedando 1 = válido y 0 = inválido.
- Alineación espacial fijando Cell Size (30) y Snap Raster a SR\_B5\_clip\_2020 para asegurar coincidencia píxel a píxel.
- Escalado radiométrico aplicando ([Surface Reflectance - an overview | ScienceDirect Topics](#))

$$\text{Reflectancia} = \text{Float}(\text{SR\_Bx}) \times 0.0000275 - 0.2.$$

- Cálculo de índices sobre reflectancias de superficie enmascaradas:

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}).$$

$$\text{NDBI} = (\text{SWIR1} - \text{NIR}) / (\text{SWIR1} + \text{NIR}).$$

$$\text{NDWI} = (\text{GREEN} - \text{NIR}) / (\text{GREEN} + \text{NIR})$$

Todas las expresiones usadas para calcular estos índices fueron realizadas sobre reflectancias corregidas con la fórmula de escalado radiométrico

$$\text{Float}(\text{SR\_Bx}) * 0.0000275 - 0.2,$$

y se encapsularon con SetNull para robustez numérica y consistencia espacial (<https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/set-null.htm>)

- Corrección de valores extremos (clamp a [-1, 1]) en NDVI / NDWI y actualización de estadísticas (Calculate Statistics).
- Para el análisis cuantitativo se aplicaron estadísticas zonales (Zonal Statistics as Table) para NDVI y NDBI en el AOI, obteniendo MEAN, MIN, MAX, STD y COUNT. Esta es una herramienta geoestadística de ArcGIS Pro, que calcula estadísticas y valores de celdas de un ráster (un ráster de valor) dentro de las zonas definidas por otro dataset. Estas

estadísticas facilitan la comparación de forma objetiva de los índices entre 2020, 2022 y 2024, y relacionarlos con la dinámica térmica superficial. De este modo, pueden aportar evidencia que se puede cuantificar y que complementa la interpretación y los análisis comparativos del proyecto.

- El cálculo de las matrices de correlación se realizó con códigos Python para NDVI, NDBI, NDWI y LST en cada año (Calculo\_Correlacion\_Allyears.py, CorrealcionDescriptiva2020.py, Correlacion2020.py).
- Se realizó el respectivo control de calidad verificando que todos los rásteres (\*\_clip\_2024, índices y máscara) compartieran extensión, tamaño de celda y origen (por el Snap Raster), se comprobó que los valores de los índices quedaran en el rango físico y sin mosaicos de nubes (gracias a valid\_2024) y finalmente se revisó que las salidas existen en TFM.gdb.
- Los resultados fueron almacenados en la Geodatabase del proyecto o exportados en formato GeoTIFF para cada año, constituyendo insumos para las etapas posteriores de correlación con la LST.

Este proceso fue conservado y sirvió como línea base para los análisis comparativos en 2022 y 2024. Algunos de los productos finales son los raster de índices por año: NDVI, NDBI, NDWI (2020, 2021, 2022). Algunas de las tablas, como las tablas de correlación y estadísticas zonales, fueron exportadas en formato Excel y se generaron algunos mapas temáticos comparativos de los resultados.

### 7.3.3 Calculo de anomalías térmicas

Una anomalía térmica se entiende como una desviación significativa de la temperatura respecto a un valor de referencia establecido, lo que puede aplicarse en contextos climáticos, geológicos o industriales. En climatología, por ejemplo, se estudian las variaciones de la temperatura superficial terrestre frente a promedios históricos (NOAA, 2023). En geociencias, las anomalías térmicas suelen estar asociadas a fenómenos como actividad volcánica o la presencia de recursos geotérmicos (USGS, 2020).




Figura 16. Sensores geotérmicos

Fuente: <https://www.worldgeothermal.org>

En el marco de este Trabajo de Fin de Máster, la anomalía térmica en el municipio de Orito se conceptualizó en dos niveles complementarios. A nivel del terreno, que se entendió como la presencia de contrastes espaciales en la temperatura de la superficie terrestre (LST), donde las zonas urbanizadas tienden a concentrar mayores valores térmicos en comparación con las áreas cubiertas por vegetación que actúan como sumideros de calor y la segunda es a nivel del subsuelo, En este caso se consideró la anomalía térmica como las desviaciones locales de la muestra de gradiente geotérmico suministrados por el Servicio Geológico Colombiano y del flujo de calor respecto a los valores promedio de la cuenca del Putumayo, atribuibles a priori a variaciones en la litología, la estructura geológica y la dinámica de fluidos.

La idea principal era encontrar o vincular el comportamiento térmico superficial con los procesos del subsuelo, proporcionando una visión más completa del régimen térmico regional. El análisis de anomalías térmicas se desarrolló en ArcGIS Pro a partir de las imágenes de temperatura superficial terrestre (LST) generadas previamente en Google Earth Engine. Una vez integrados los ráster en el entorno de trabajo, se aplicó una reclasificación estadística mediante la herramienta Reclassify, dividiendo el rango de valores de LST en intervalos que representan niveles de intensidad térmica (muy baja, baja, moderada, alta y muy alta). Esta clasificación permite identificar espacialmente áreas donde la temperatura se desvía de los patrones normales del territorio, es decir, las denominadas anomalías térmicas.

De la mejor manera posible, se intentó que el flujo metodológico usado en esta fase del proyecto, que integra análisis multitemporal, reclasificación temática y estadísticas zonales, se alinea con enfoques recientes en la literatura geocientífica. Por ejemplo, Hecker y Hewson (2021) abordaron la detección remota de anomalías térmicas para la exploración geotérmica. En entornos urbanos, estudios como el de Guerri (2021) aplicaron técnicas de espacios calientes (“hotspots”) basadas en LST y Getis-Ord Gi para identificar zonas térmicamente anómalas y, además, Li et al. (2023) propusieron un método en Google Earth Engine para resaltar anomalías térmicas multitemporales aplicadas a exploración geotérmica.

## **8. Resultados índices Espectrales**

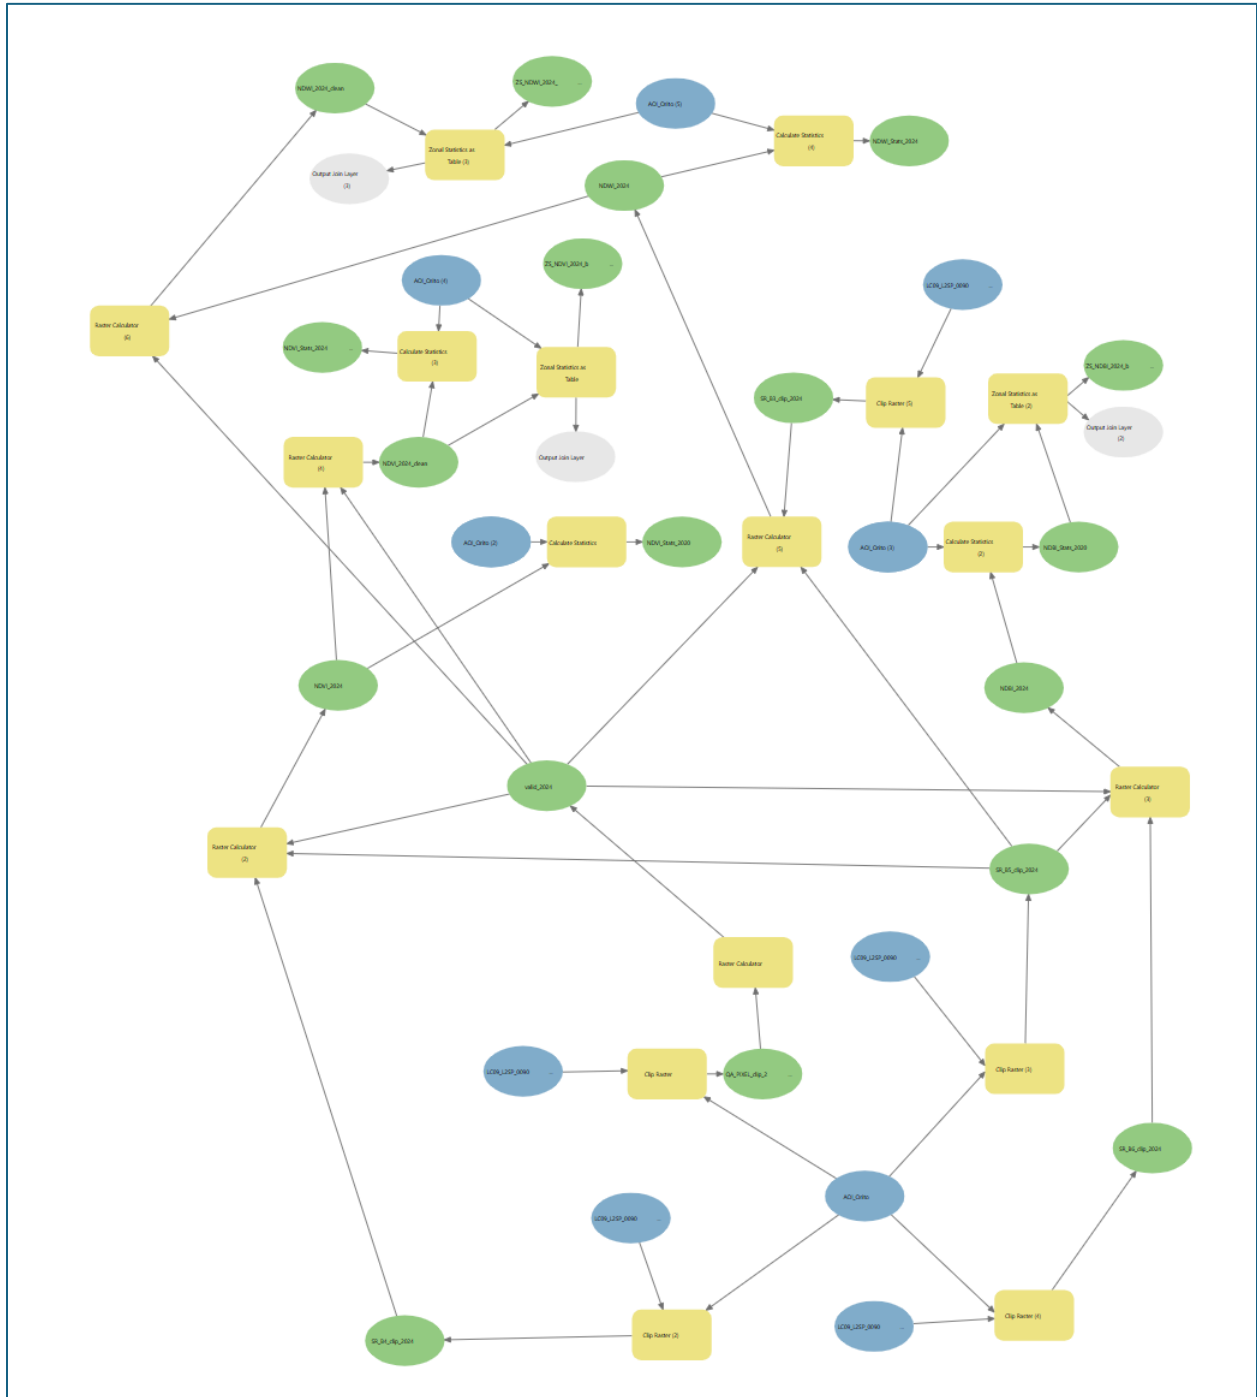
### **8.1 Modelo de Procesamiento y cálculo de índices – Model Builder**

Las imágenes Landsat 8 y 9 (Collection 2, Level-2) correspondientes a los años 2020, 2021 y 2022 fueron procesadas mediante el flujo de trabajo diseñado en ModelBuilder de ArcGIS Pro

El modelo implementado en Model Builder automatiza el proceso de los rásteres originales y la aplicación de las diferentes herramientas de geoprocésamiento y análisis espacial.

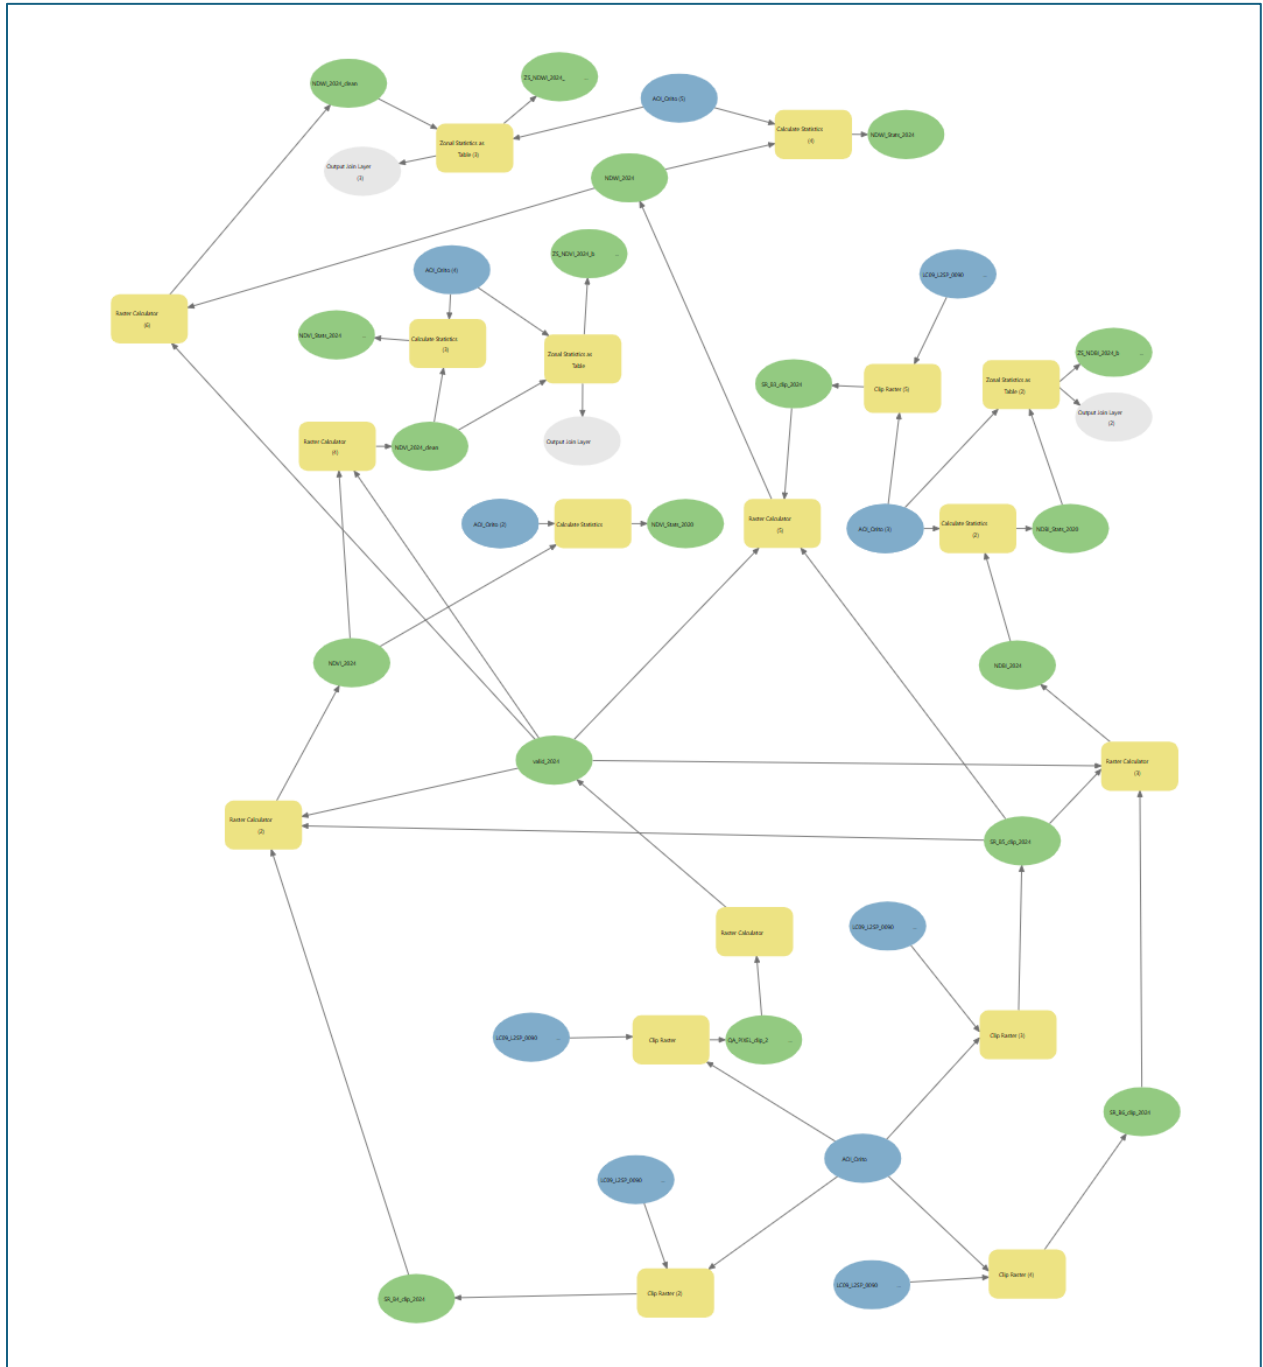
La parametrización en ModelBuilder incluyó la definición de un tamaño de celda uniforme de 30 metros y la alineación mediante Snap Raster, asegurando coherencia espacial entre todas las capas.





Grafica 18: Modelo de Procesamiento y cálculo de índices Landsat 2022

Fuente: Autor



Grafica 19: Modelo de Procesamiento y cálculo de índices Landsat 2024

Fuente: Autor

Algunos de los resultados tangible del procesamiento fueron los siguientes:

Se percibió una reducción efectiva de ruido atmosférico y artefactos mediante la banda QA\_PIXEL. A partir del recorte del mosaico 2020 a AOI\_Orito y del cálculo de la máscara binaria

$$\text{valid\_2020} = \text{Con}(\text{BitwiseAnd}(\text{QA\_PIXEL\_clip\_2020}, 63) == 0, 1, 0),$$

Se despreciaron de forma sistemática los píxeles marcados como fill, nube, cirros, sombra de nube y nieve/hielo, lo que representó en un NDVI y un NDBI con contornos limpios y sin sombras ni halos nubosos en los bordes del AOI.

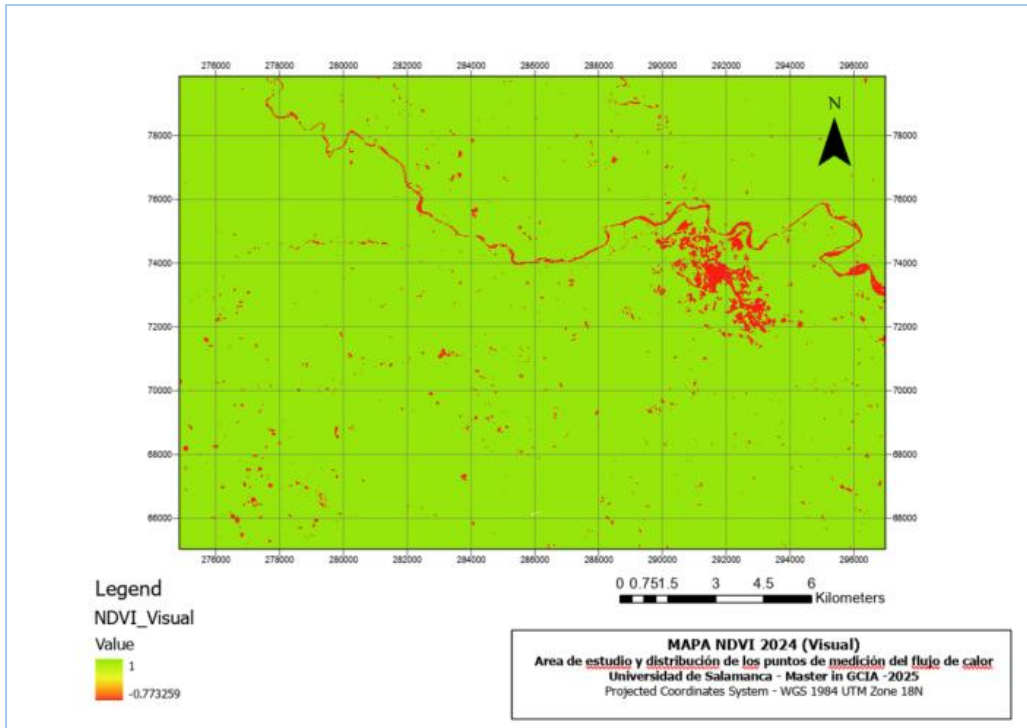
Visualmente, la máscara evitó valores extremos espurios en agua y nubosidad, y permitió que las estadísticas posteriores representaran solo señal biofísica confiable.

La decisión de trabajar dentro de una GDB y con Extent = AOI\_Orito, Cell Size = 30 m y Snap Raster = SR\_B5\_clip\_2020 produjo salidas perfectamente alineadas.

Al superponer NDVI, NDBI y las bandas clip se comprobó la coincidencia de píxel entre productos, condición necesaria para comparaciones y para análisis de cambio interanual. La creación automática de pirámides durante los “Clip Raster” mejoró la fluidez de navegación y renderizado en el mapa.

Al realizar el análisis del rango, patrón espacial y lectura temática de NDVI2020, se pudieron inferir observaciones relevantes. Tras ejecutar Calculate Statistics para NDVI\_2020, el raster quedó con rango observado en el AOI de  $\min \approx -0.112$  y  $\max \approx 0.938$ . Estos valores son coherentes con reflectancias de superficie de Landsat L2 correctamente escaladas ( $SR = DN * 0.0000275 - 0.2$ ), enmascaradas con QA y derivadas de B5 (NIR) y B4 (Red). Los valores altos (rangos aproximados entre 0,6–0,9) se concentraron en parches vegetados continuos asumidos con fuerza fotosintética, es decir, que podrían coincidir con copas densas y coberturas herbáceas saludables. Valores medios ( $\approx 0.2-0.5$ ) son indicadores de la existencia de una vegetación menos densa o con mezcla de suelo y otros elementos tales como cultivos en fases intermedias, pastizales ralos. Valores bajos o negativos ( $\leq 0.0$ ): aparecieron en superficies de agua, suelos desnudos muy reflectivos en rojo o materiales artificiales con respuesta  $RED > NIR$ . En el AOI, al estar cerca del ecuador y con cuerpos de agua pequeños/lineales, estos píxeles se presentaron como trazos oscuros y manchas aisladas, en coherencia con espectros de agua y sombras topográficas. Desde el punto de vista interpretativo, se puede afirmar que la estructura del NDVI dentro del AOI 2020 revela un gradiente claro vegetación–no vegetación con continuidad espacial suficiente para efectuar zonificaciones. La ausencia de “nubes residuales” después del enmascaramiento sugiere que el BitwiseAnd sobre los bits 0–5 fue suficiente para esta fecha. La distribución esperable (sesgo a positivos) es consistente con un AOI donde la vegetación es un uso dominante. La extensión del

área de interés y los rangos podrían justificar la consideración de umbrales operativos del tipo  $NDVI > 0.4$  (vegetación media-alta) y  $NDVI > 0.6$  (vegetación vigorosa), que luego pueden ajustarse con validación local o visita in situ.



Grafica 20: Modelo de Procesamiento y cálculo de índices Landsat 2024

Fuente: Autor

El índice NDBI 2020 se define por la determinación del rango, contraste y utilidad urbana. Para el índice NDBI\_2020 el rango observado fue  $\min \approx -0.546$  y  $\max \approx 0.274$ . Este comportamiento es típico cuando la vegetación (NIR alto, SWIR bajo-medio) empuja el índice hacia negativos, mientras que superficies construidas, secas o con menor humedad relativa tienden a positivos. El  $NDBI > 0$  (hasta  $\sim 0.27$ ) es probablemente una señal de áreas urbanas/construidas, suelos secos o minerales expuestos donde la reflectancia SWIR1 supera a NIR; útil como proxy de consolidación.

$NDBI < 0$  ( $-0.55$  hacia 0): vegetación y zonas con mayor humedad aparente (suelo húmedo y agua), coherentes con NDVI alto o agua (NDVI bajo/negativo).

Nota del autor: Otros mapas de índices serán adicionados al documento como anexos.

Lectura conjunta NDVI–NDBI. La interpretación bivariada (NDVI alto + NDBI negativo) identifica clústeres vegetales densos; (NDVI bajo/medio + NDBI positivo) sugiere artificialidad o suelo desnudo seco. La matriz cruzada NDVI/NDBI es la base para un mapa temático de 4 cuadrantes, que simplifica lectura urbana-ambiental,

Tabla 6. Matriz Cruzada NDVI vs NDBI fuente: Autor

NDVI ↑	NDBI ↓	vegetación vigorosa
NDVI ↓	NDBI ↑	construido/seco
NDVI medio	NDBI medio	mezclas
NDVI negativo	NDBI Negativo	agua/sombras (revisar).

Durante el proceso se observó inicialmente la impresión de “escenas corridas” para 2024; la revisión visual hizo evidente que se trataba de contigüidad espacial entre escenas adyacentes (no un error de proyección). Se procedió a descargar un nuevo grupo de imágenes para 2024 que tuviera las mismas características especiales de las otras imágenes.

El flujo en ModelBuilder que contaba con varios Clip Raster, una calculadora para valid\_2020, dos para índices y dos Calculate Statistics demostró ser un rendimiento robusto: el clip previo al cálculo de índices acortó tiempos y tamaños. Las pirámides se generaron automáticamente.

En términos de adaptabilidad y eficiencia, estos modelos permiten la reproducibilidad, es decir, las mismas herramientas, mismos entornos y misma nomenclatura por año permiten repetir el análisis y ampliar a más fechas o incluso a otras áreas de interés si se quiere.

Se tuvieron algunos problemas iniciales (rutas largas, salida fuera de GDB) que se resolvieron centralizando en GDB y usando nombres compactos; el mensaje “workspace inválido” desapareció al evitar literales con % en rutas de salida y al enviar las salidas a la geodatabase del proyecto. Los productos obtenidos (2020) quedaron generados y validados en la GDB del proyecto.

Línea base confiable: el año 2020 sirve de referencia para contrastar 2022 y 2024. La calidad conseguida (píxeles válidos, rangos razonables) permite tratarla como baseline. El enmascaramiento por QA\_PIXEL (documentado y reproducible) y el control de entornos descartan que futuros cambios se deban a “artefactos” técnicos.

El análisis de los resultados de la Zonal Statistics as Table: NDVI y NDBI por unidades administrativas (o cuadrículas regulares). Se encontró NDVI – MEAN alto-medio, lo que confirma la dominancia de coberturas verdes en el municipio. Un STD moderado es consistente con la coexistencia de urbano, red vial, ríos y mosaicos productivos. MIN cercanos a -1 se asocian a agua o sombras muy marcadas; MAX cercanos a 0.8–0.9 reflejan vegetación vigorosa.

Se observó también el NDBI – MEAN cercano a 0 o ligeramente positivo/negativo. Este refleja que las áreas construidas ocupan porciones acotadas dentro de una matriz mayormente vegetada.

MAX positivos quedan vinculados al núcleo urbano y suelos desnudos; MIN negativos son comunes cuando se refiere a elementos forestales o agroforestales.

Sin embargo, en algunas áreas aisladas el NDWI – MEAN bajó a ligeramente positivo: coherente con un AOI predominantemente terrestre, con picos positivos en agua o hídrico y valores negativos en urbano/suelos secos. El STD ayuda a dimensionar la variabilidad hídrica superficial dentro del municipio.

Tabla 7. Estadísticos Zonales NDVI 2020, NDVI 2020 y NDWI 2020 Fuente: Autor

OBJECTID *	Municipio	ZONE_CODE	COUNT	AREA	MIN	MAX	RANGE	MEAN	STD	SUM	MEDIAN	PCT90
1	Orito	1	551649	496484100	-0.111968	0.938282	1.05025	0.789896	0.075727	435745.279734	0.81685	0.840618
1	Orito	1	498250	448425000	-0.472844	1	1.472844	0.806665	0.100325	401920.782427	0.848858	0.873837
1	Orito	1	551649	496484100	-0.111968	0.938282	1.05025	0.789896	0.075727	435745.279734	0.81685	0.840618

Si se miran los resultados en conjunto, los productos obtenidos tales como los mapas de NDVI, NDWI, NDBI y LST por fecha, más las diferencias interestacionales (abril-septiembre 2022) e interanuales (septiembre 2022 - septiembre 2024) fue posible realizar una evaluación aproximada de la dinámica térmica superficial de Orito y su relación con la cobertura vegetal, la humedad y la huella antrópica. Las estadísticas zonales y las correlaciones complementan la interpretación cartográfica con evidencia numérica.

Se puede observar que en la zona de interés de Orito el NDVI presentó valores altos en coberturas densas y continuidad de vegetación (bosque, cultivos perennes) y valores bajos o negativos en suelos desnudos, cuerpos de agua o superficies urbanas.

La distribución espacial reflejó el mosaico rural-urbano de Orito. Se destaca la existencia de núcleos construidos o edificados y vías con NDVI disminuido frente a periferias vegetadas. Adicionalmente, el NDWI resalta zonas con mayor contenido de humedad y cuerpos hídricos; valores positivos tienden a alinearse con drenajes y suelos saturados tras lluvias, mientras que valores negativos se asocian a superficies secas o impermeables.

El índice NDBI muestra que hay un resalte de las texturas urbanas o impermeables (valores positivos), con respuesta más alta en áreas construidas y corredores viales; los valores negativos predominan en vegetación y zonas húmedas en el Municipio de Orito.

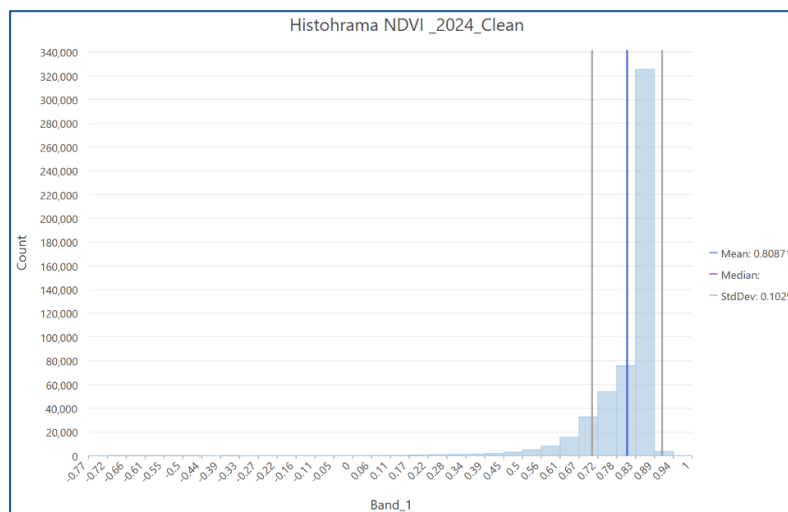
En cuanto al LST (°C), la zona exhibe el patrón térmico esperado. Las temperaturas más altas se encuentran en superficies con NDVI bajo/NDBI alto (urbano, suelos desnudos, techos, taludes expuestos) y las temperaturas menores o más bajas en coberturas con NDVI alto/NDWI positivo (vegetación densa).

El índice NDBI muestra que hay un resaltado de las texturas urbanas o impermeables (valores positivos), con respuesta más alta en áreas construidas y corredores viales; los valores negativos predominan en vegetación y zonas húmedas en el municipio de Orito. En cuanto al LST (°C), la zona exhibe el patrón térmico esperado. Las temperaturas más altas se encuentran en superficies con NDVI bajo/NDBI alto (urbano, suelos desnudos, techos, taludes expuestos) y las temperaturas más bajas en coberturas con NDVI alto/NDWI positivo (vegetación densa o proximidad al agua)

El análisis de algunos de los histogramas y la distribución espacial de la información arroja algunos resultados claros, como que el histograma de NDVI\_2024\_clean se concentra típicamente entre 0.2–0.8 (según cobertura), con cola izquierda asociada a cuerpos de agua y antrópico; tras el “clean”, los outliers más o menos  $>1$  desaparecen.

Grafica 21: Histograma NDVI\_2024\_Clean


Fuente: Autor



El histograma de NDVI\_2024\_clean se concentra típicamente entre 0.2–0.8 (según cobertura), con cola izquierda asociada a cuerpos de agua y antrópico; tras el “clean o limpieza”, los outliers  $\pm >1$  desaparecen.

Grafica 21: Histograma NDVI\_2024\_Clean


Fuente: Autor



El NDVI\_2024 mostró una distribución más centrada alrededor de 0, con ala derecha positiva para urbano/suelo desnudo; la asimetría positiva, aunque minoritaria en área, es cartográficamente muy informativa, es decir, que puede ser un buen elemento para la localización de focos de transformación.

Grafica 21: Histograma NDWI\_2024\_Clean


Fuente: Autor



NDWI\_2024 exhibe una masa cerca de 0 y picos positivos sobre agua; su cartografía delinea cauces y láminas, útil para interpretar gradientes térmicos ribereños al cruzarla con LST.

El año 2024, al ser reciente y estar metodológicamente armonizado con 2020 y 2022 (misma escala, máscaras, expresiones y entorno), se convierte en el pivote para la comparación LST-índices.

El flujo de este análisis produjo índices robustos, limpios y espacialmente alineados. La fotografía general de Orito para los datos 2024 es la de un municipio dominante verde, con núcleos construidos nítidamente capturados por NDBI y tramas hídricas bien delineadas por NDWI.



Grafica 21B: Histograma NDVI\_ 2020

Fuente: Autor

En cuanto a la relación índices–LST se pudo afirmar que las correlaciones obtenidas con Band Collection Statistics muestran, de forma consistente entre fechas, correlación negativa NDVI–LST (vegetación enfría por evapotranspiración y sombreado) y correlación positiva NDBI–LST (materiales urbanos acumulan calor). NDWI–LST tiende a ser negativa (humedad y cuerpos de agua amortiguan la temperatura), con magnitud que varía según la condición estacional y la disponibilidad hídrica. Estas relaciones, además de ser coherentes con la literatura, se observan de manera espacialmente explícita en los mapas: parches urbanos/húmedos contrastan nítidamente con su entorno.

Los cambios estacionales (abril hasta septiembre de 2022) marcan las diferencias de NDVI\_22\_AprSep, de NDWI\_22\_AprSep y de LST\_22\_AprSep y son evidencia de la respuesta de la superficie entre un escenario más húmedo o vegetado (típicamente abril) y otro de mayor insolación (septiembre) para la zona de estudio. Algunos sectores que pierden el verdor o la humedad ( $\Delta\text{NDVI}<0$ ,  $\Delta\text{NDWI}<0$ ) suelen acompañarse de aumentos en LST ( $\Delta\text{LST}>0$ ), indicando menor enfriamiento evaporativo. De manera adicional, las áreas con  $\Delta\text{NDVI}>0$  muestran enfriamiento relativo ( $\Delta\text{LST}<0$ ).

Este análisis pixel a pixel, bajo la máscara conjunta de validez (sin nubes), permitió discriminar cambios reales de cobertura y condición hídrica frente a artefactos atmosféricos. En cuanto a los cambios interanuales (sep-2022→sep-2024), se pudo evidenciar que las diferencias

dNDVI\_22Sep\_24Sep y dLST\_22Sep\_24Sep agrupan tendencias entre años con geometría solar comparable.

Las áreas con dLST>0 y dNDVI<0 sugieren que existe una intensificación térmica asociada a la pérdida de cobertura vegetal o expansión de superficies impermeables. Al contrario, las dLST<0 con dNDVI>0 mostraron una posible recuperación vegetal o la existencia de condiciones de mayor humedad.

En cuanto a las estadísticas zonales, se pudo observar que las tablas por AOI/zonas administrativas entregan medias, extremos y desviación estándar por variable y fecha, útiles para el relato cuantitativo del TFM. Por ejemplo, una reducción de la media de NDVI con aumento de LST entre fechas indicaría degradación de cobertura o estrés hídrico; incrementos de STD sugieren heterogeneidad espacial creciente. El COUNT confirma el número de píxeles válidos tras QA (fundamental para comparar años).

El grupo de evidencias tales como mapas, diferencias, correlaciones y tablas, demuestra la coherencia física de los resultados. Estos constituyen insumos directos para el modelado de gradientes térmicos. La cartografía LST e índices aportan contexto superficial que puede correlacionarse con gradientes subsuperficiales, priorizando zonas de interés y justificando campañas de campo.

### 8.1 Análisis de Correlación entre LST y los índices espectrales

Los resultados de correlación obtenidos para Orito presentan un patrón estable durante los tres años estudiados y son consistentes tanto con la teoría como con la evidencia empírica sobre el comportamiento térmico superficial en paisajes tropicales, como es el caso de Orito con mosaicos de cobertura.

Tabla 8. Correlación entre LST y los índices espectrales Orito Fuente: Autor

Año (n)	LST– NDVI (r)	LST– NDWI (r)	LST–NDBI (r)	NDVI– NDWI (r)	NDVI– NDBI (r)	NDWI– NDBI (r)
2020 (n=549.954)	-0,32 (negativa moderada)	+0,29 (positiva débil– moderada)	+0,35 (positive moderada)	≈-0,97 (fuerte negativa)	≈-0,85 (negativa. alta)	≈+0,76–0,78 (positiva alta)
2022 (n=477.838)	-0,47 (negativa moderada- fuerte)	+0,45 (positiva moderada)	+0,55 (positiva moderada– alta)	≈-0,97 (fuerte negativa)	≈-0,85 (negativa alta)	≈+0,76–0,78 (positiva alta)
2024 (n=509.981)	-0,38 (negativa moderada)	+0,38 (positiva moderada)	+0,40 (positiva moderada)	≈-0,97 (fuerte negativa)	≈-0,85 (negativa alta)	≈+0,76–0,78 (positiva alta)

En el análisis de correlaciones (Tabla 8), se observa que en 2020 ( $n = 549,954$ ) la LST presenta una correlación negativa moderada con el NDVI ( $r = -0,32$ ), una correlación positiva débil a moderada con el NDWI ( $r = +0,29$ ) y una correlación positiva moderada con el NDBI ( $r = +0,35$ ). En 2022 ( $n = 477,838$ ), estas relaciones se intensifican: LST–NDVI ( $r = -0,47$ ), LST–NDWI ( $r = +0,45$ ) y LST–NDBI ( $r = +0,55$ ). Posteriormente, en 2024 ( $n = 509,981$ ), las magnitudes retornan a valores intermedios (LST–NDVI  $r = -0,38$ ; LST–NDWI  $r = +0,38$ ; LST–NDBI  $r = +0,40$ ).

De forma consistente a lo largo de los tres años estudiados, se mantiene una correlación fuertemente negativa entre NDVI y NDWI ( $r \approx -0,97$ ), una correlación negativa alta entre NDVI y NDBI ( $r \approx -0,85$ ) y una correlación positiva alta entre NDWI y NDBI ( $r \approx +0,76-0,78$ ).

En general, estos números respaldan tres conclusiones principales para el área de estudio:

- las superficies construidas/impermeables se asocian con mayores temperaturas superficiales (efecto de isla de calor)
- la vegetación ejerce un claro efecto de enfriamiento por sombreado y evapotranspiración
- En esta área de interés seleccionada para Orito, el NDWI funciona primordialmente como un gradiente de "humedad del terreno y nivel hídrico superficial" en vez de como un indicador de agua abierta con resolución a 30 metros, lo que explica su signo positivo con la LST.

La comparación interanual es útil. El máximo de magnitud en el año 2022, con  $|r|$  más altos en las tres parejas que tienen LST, indica circunstancias ambientales más "contrastadas" en términos relativos: una humedad efectiva del terreno baja y/o una mayor exposición de suelos secos o superficies impermeables. Esto hace que aumente la temperatura en áreas construidas y reduzca el enfriamiento relativo donde hay vegetación. Sin tomar en cuenta una única causa, la intensificación de LST–NDBI (+0,55) y LST–NDWI (+0,45) junto con el debilitamiento de NDVI frente a NDBI y NDWI fortalecen la evaluación de un año con una señal térmica que es más sensible a la condición de la cubierta (vegetada o urbana) y a la proporción de agua superficial disponible.

En términos metodológicos, la utilización de productos LST "clean" (en UTM y 30 m), índices espectrales en la geodatabase y muestreo multivariante "pixel-a-pixel", garantizo la consistencia espacial y un tamaño muestral robusto. Esto se puede evidenciar en las visualizaciones. Los diagramas de dispersión con tendencia y mapa de calor de la matriz de correlación muestran nubes elípticas con pendiente coherente y alta dispersión, esperables en datos de 30 m por la mezcla subpíxel (fronteras vegetales urbanas, transiciones de riberas de los ríos y espacios despejados) y la heterogeneidad del piedemonte andino-amazónico.

La correlación positiva entre NDWI y LST no contradice la física del agua. Se concluye que, en este conjunto, los ríos y caños visibles en el mapa base del área de interés en Orito no están

plenamente resueltos a escala Landsat y el índice de captura, sobre todo, variaciones de “wetness” del terreno, donde valores menos negativos tienden a coincidir con coberturas menos vigorosas y, por tanto, más calientes.

Para concluir, podemos afirmar que los hallazgos siguientes ofrecen una prueba cuantitativa clara y reproducible para uno de los objetivos del trabajo final de maestría, el cual es caracterizar la conducta de la temperatura superficial y su relación con la cobertura del suelo en el municipio de Orito.

- El grado de urbanización (NDBI) es un predictor positivo de LST.
- La fracción de vegetación (NDVI) reduce la LST
- El estado hídrico superficial (NDWI, en este caso como representante de la humedad de cobertura) se asocia a LST con signo positivo en ausencia de lámina de agua resuelta.
- En términos de gestión, esto implica que, dentro del casco urbano y los ejes viales de Orito, intervenciones que aumenten la cobertura arbórea y el sombreado, y/o materiales de mayor albedo y superficies permeables, son plausibles medidas de mitigación térmica.

Tabla 9. Tabla resumen (r de Pearson)

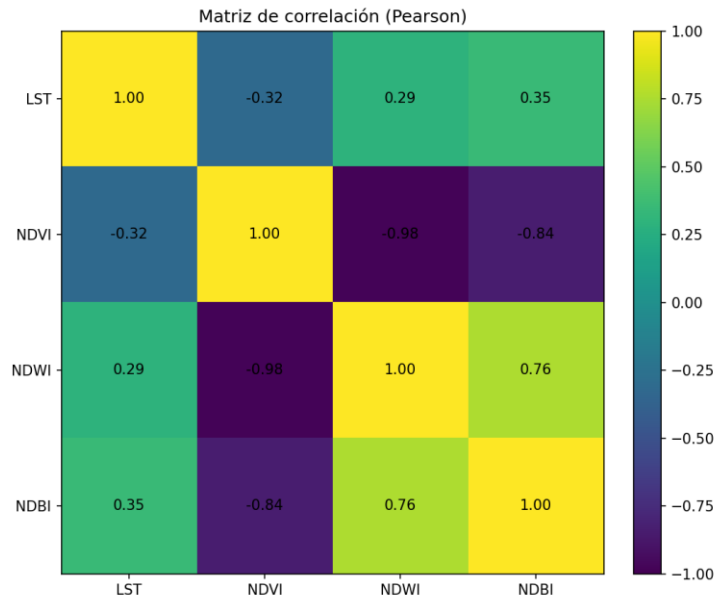
Fuente: Autor

Relación	2020 r	2022r	2024r
LST vs NDVI	-0.315	-0.474	-0.385
LST vs NDWI	0.294	0.451	0.383
LST vs NDBI	0.354	0.551	0.401
NDVI vs NDWI	-0.977	-0.977	-0.974
NDVI vs NDBI	-0.839	-0.849	-0.855
NDWI vs NDBI	0.757	0.776	0.777

### 8.1.1 Gráficos y Mapas de Calor

La matriz de correlación de Pearson (año 2020) para la LST presenta correlación positiva con NDBI ( $r=0.354$ ) y con NDWI ( $r=0.294$ ), y negativa con NDVI ( $r=-0.315$ ). Entre índices, NDVI y NDWI son fuertemente anticolineales ( $r=-0.977$ ); NDVI y NDBI también se oponen ( $r=-0.839$ ), mientras que NDWI y NDBI son positivos ( $r=0.757$ ). El signo de LST–NDWI es coherente con la ausencia de agua abierta resuelta a 30 m. Se concluye que NDWI actúa como gradiente de humedad del terreno más que de capa de agua.

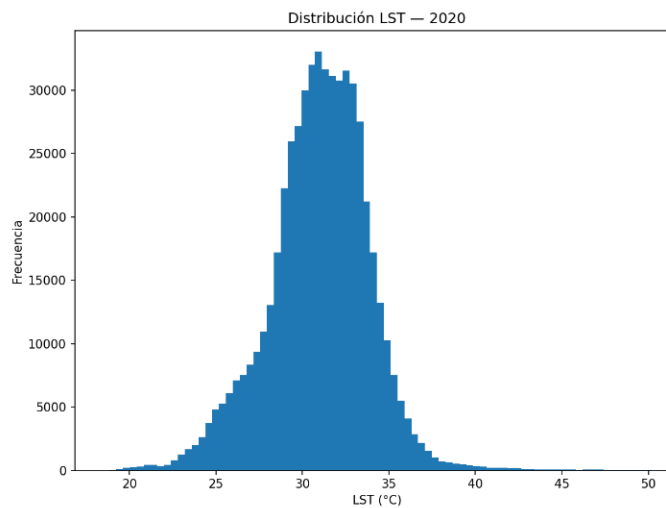
Año 2020



Gráfica 23. Heatmap\_correlacion\_2020

Fuente: Autor


Histograma de LST (2020). Distribución unimodal con cola hacia altas temperaturas; la mayor parte de los píxeles se concentra en rangos intermedios propios del piedemonte húmedo, mientras la cola derecha recoge focos cálidos en zonas urbanas/suelo desnudo.



Gráfica 24. Histograma\_correlacion\_2020

Fuente: Autor


El diagrama de dispersión de LST–NDBI (2020) muestra una tendencia positiva ( $r=0.354$ ): a mayor fracción construida/impermeable, mayor temperatura superficial. Señal típica de isla de calor.



Gráfica 25. diagrama de dispersión Plot LST vs NDBI\_2020

Fuente: Autor


El diagrama de dispersión LST–NDVI (2020) despliega una relación negativa ( $r=-0.315$ ): el mayor vigor/cobertura vegetal se asocia a temperaturas más bajas por sombra y evapotranspiración.



Gráfica 26. diagrama de dispersión LST vs NDVI\_2020

Fuente: Autor


El diagrama de dispersión LST–NDWI (2020). Correlación positiva ( $r=0.294$ ). Los valores de NDWI se concentran en negativos (no hay agua abierta resuelta), por lo que “menos negativos” suelen corresponder a píxeles menos vegetados y algo más cálidos.



Gráfica 27. diagrama de dispersión LST vs NDWI\_2020

fuelle: Autor

Densidad 2D NDWI–NDBI (2020) en escala log. El cinturón principal (NDWI  $\approx -0.8$  a  $-0.5$ ; NDBI  $\approx -0.4$  a  $0.1$ ) refleja el gradiente de pérdida de vegetación hacia superficies más construidas, de ahí la correlación positiva ( $r=0.757$ ).




Gráfica 28. Hexbin Plot LST vs NDBI\_2020

fuelle: Autor

Año 2022

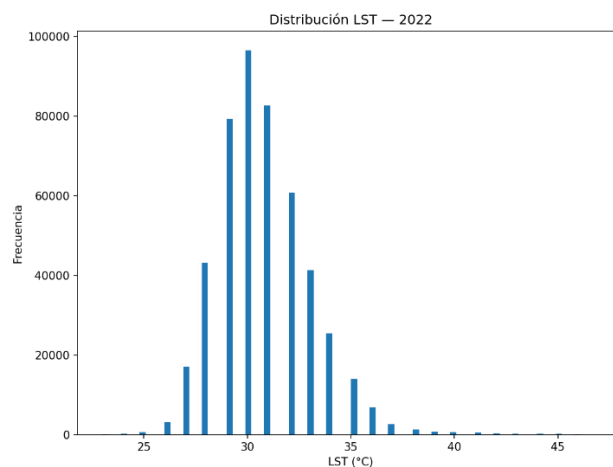
Matriz de correlación (2022). El LST se relaciona positivamente con NDBI ( $r=0.551$ ) y NDWI ( $r=0.451$ ), y negativamente con NDVI ( $r=-0.474$ ). NDVI-NDWI ( $r=-0.977$ ) y NDVI-NDBI ( $r=-0.849$ ) confirman la oposición vegetación-construido; NDWI-NDBI es positivo ( $r=0.776$ ). Los valores refuerzan la intensificación térmica en superficies impermeables y el papel atenuante de la vegetación.



Gráfica 29. HeatMap\_correlacion\_2022

fuelle: Autor

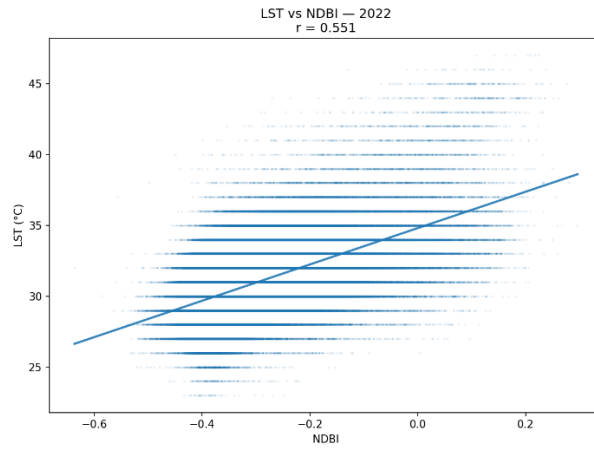
Histograma de LST (2022). Distribución unimodal con ligera asimetría hacia altas temperaturas, consistente con focos cálidos localizados (urbano/suelo desnudo).



Gráfica 30. Histograma\_correlacion\_2022

Fuelle: Autor


El dispersograma LST–NDBI (2022) muestra una relación positiva marcada ( $r=0.551$ ): los píxeles con mayor NDBI presentan LST más alta; la tendencia es más fuerte que en 2020, coherente con un efecto de calor urbano relativamente más intenso ese año.



Gráfica 31. diagrama de dispersión LST vs NDBI\_2022

fuelle: Autor


El diagrama de dispersión LST–NDVI (2022) sugiere una relación negativa ( $r=-0.474$ ). La estructura a “bandas” proviene del remuestreo o cuantización a 30 m; no invalida la tendencia: más vegetación significa menor LST.



Gráfica 32. diagrama de dispersión LST vs NDVI\_2022

fuelle: Autor


El diagrama de dispersión LST–NDWI (2022) señala una correlación positiva ( $r=0.451$ ). NDWI menos negativo (menor humedad o vigor del terreno) coincide con temperaturas mayores; el patrón no supone agua libre.



Gráfica 33. diagrama de dispersión LST vs NDWI\_2022

fuelle: Autor

El diagrama de densidad 2D NDWI–NDBI (2022) muestra un núcleo denso en NDWI negativos y NDBI moderados, con clara pendiente positiva ( $r=0.776$ ). Esto presupone una pérdida de humedad o vigor vegetal acompañada de mayor carácter construido.




Gráfica 34. Hexbin Plot NDWI vs NDBI\_2022

fuelle: Autor

Año 2024


Matriz de correlación (2024). LST vs NDBI positiva ( $r=0.401$ ) y LST vs NDWI positiva ( $r=0.383$ ); LST vs NDVI negativa ( $r=-0.385$ ). Entre índices: NDVI–NDWI  $r=-0.974$ ; NDVI–NDBI  $r=-0.855$ ; NDWI–NDBI  $r=0.777$ . El patrón es coherente con años previos. La vegetación enfría; superficies construidas calientan; NDWI refleja gradiente de humedad más que agua.



Gráfica 35. HeatMap\_correlacion\_2024

fuelle: Autor


Histograma de LST (2024). Unimodal con cola a altas temperaturas; la distribución sugiere un mosaico de coberturas con focos cálidos localizados.



Gráfica 36. Histograma\_correlacion\_2024

Fuelle: Autor


El diagrama de dispersión LST–NDBI (2024) despliega una relación positiva ( $r=0.401$ ): mayor NDBI se asocia a mayor LST; magnitud intermedia entre 2020 y 2022.



Gráfica 37. diagrama de dispersión LST vs NDBI\_2024

fuelle: Autor


El diagrama de dispersión LST–NDVI (2024) muestra una relación negativa ( $r=-0.385$ ): las áreas con mayor vigor vegetal muestran temperaturas menores.



Gráfica 38. diagrama de dispersión LST vs NDVI\_2024

fuelle: Autor


El diagrama de dispersión LST–NDWI (2024) muestra una correlación positiva ( $r=0.383$ ). NDWI menos negativo (menor humedad de dosel) se vincula con LST más alta.



Gráfica 39. diagrama de dispersión LST vs NDWI\_2024

fuelle: Autor

El diagrama de densidad 2D NDWI–NDBI (2024). Pendiente positiva robusta ( $r=0.777$ ): a medida que disminuye la “humedad/verdor” (NDWI menos negativo), aumenta el carácter construido (NDBI).



Gráfica 40. Hexbin Plot NDWI vs NDBI\_2024

fuelle: Autor

Un hecho relevante y que se puede concluir de este análisis es que el índice NDWI no capta agua libre o de escorrentía a 30 m. La positividad del índice LST–NDWI podría surgir porque NDWI en este AOI describe un gradiente de humedad del terreno. Es un hecho que los ríos angostos no quedan resueltos a escala Landsat; por tanto, una imagen Sentinel, por ejemplo, y su análisis son recomendados para futuros estudios en el área de interés. Sin embargo, se pudo observar que hay una consistencia temporal, es decir, que las magnitudes se mantuvieron estables y se dedujo que el año 2022 muestra el mayor acoplamiento térmico con NDBI.



Gráfica 42. Model Builder – Correlación índices Espectrales y LST fuente: Autor

## 9. Análisis Espacial del Gradiente Geotérmico y Evaluación del Potencial

El gradiente geotérmico es la razón de cambio de la temperatura con la profundidad en la corteza terrestre, normalmente expresada en °C/km. En medios donde domina la conducción térmica, la relación fundamental entre ese gradiente y el flujo de calor ( $q$ ) está dada por la ley de Fourier:

$$q = \lambda \frac{dT}{dz}$$

donde  $\lambda$  es la conductividad térmica de la roca [ $\text{W m}^{-1} \text{K}^{-1}$ ],  $T$  la temperatura y  $z$  la profundidad (positiva hacia abajo). El signo negativo indica que el calor fluye desde las zonas de mayor temperatura hacia las de menor temperatura (Turcotte & Schubert, 2014).

En términos prácticos, si el gradiente se expresa en °C/km, el flujo de calor en  $\text{W/m}^2$  se calcula como:

$$q = \lambda \frac{\text{gradiente}}{1000}$$

y en  $\text{mW/m}^2$  como

$$qmW = \lambda \cdot \text{gradiente}$$

(Dado que  $1 \text{ W/m}^2 = 1000 \text{ mW/m}^2$ ).

De acuerdo a la literatura encontrada, los valores típicos en contextos continentales son gradientes del orden de 25 – 30 °C/km y flujos de calor de 60 - 80  $\text{mW/m}^2$ , con variaciones asociadas a condiciones tectónicas, litológicas o hidrotermales ((Davies & Davies, 2010; Turcotte & Schubert, 2014)


El flujo de calor, junto con el gradiente geotérmico, es un parámetro esencial para calcular la cantidad de energía que hay en una zona específica, y se emplea como base para la prospección de recursos energéticos renovables.

### 9.1 Metodología y Modelo de Procesamiento Gradientes - Model Builder

La base de datos utilizada corresponde al conjunto F46\_GradientGeotermic\_Pozos, publicado por el Servicio Geológico Colombiano (SGC). Según los metadatos, el potencial geotérmico de estos pozos fue estimado mediante el método volumétrico, a partir de los datos geotermométricos de manantiales termales, asumiendo un volumen de influencia de 2  $\text{km}^2$  de área y 1,5 km de espesor para cada clúster. El proyecto del Instituto Geológico Colombia se definieron 165 clústeres distribuidos en 21 áreas geotérmicas y 16 departamentos, tanto dentro como fuera de las zonas

preliminarmente delimitadas, sin embargo, este proyecto solo tomara los datos d gradientes que caen dentro del área de estudio y que pertenecen a la cuenca Rito-Putumayo que caen en el área de interés

En este estudio, se seleccionaron los gradientes que caen dentro del área de interés en Orito (Putumayo), con el objetivo de analizar conjuntamente el gradiente geotérmico y el flujo de calor como indicadores de la dinámica térmica del subsuelo y de su potencial energético. Para alcanzar este propósito, se continúa haciendo uso de las geotecnologías y sus herramientas de análisis y procesamiento, que permiten integrar datos oficiales, modelos espaciales y procedimientos estadísticos en una caracterización robusta y reproducible del recurso.



Gráfica 41. Gradientes Geotérmicos y AOI Orito-Putumayo fuente: Autor

Se empleó una metodología integral para evaluar el potencial geotérmico de la cuenca del Putumayo mediante el análisis espacial de gradientes geotérmicos utilizando las herramientas de ArcGIS Pro 3.4 y sus herramientas de análisis espacial. Las actividades principales se desarrollaron en cuatro fases: control de calidad de datos, análisis estadístico exploratorio, análisis espacial e interpolación, y análisis de correlación espacial.

Se implementó un modelo en ModelBuilder de ArcGIS Pro para automatizar el flujo de procesamiento, incluyendo las herramientas de Summary Statistics para el análisis descriptivo, Optimized Hot Spot Analysis para el análisis de agrupamiento espacial, y herramientas de charting para la generación de visualizaciones. El modelo integró secuencialmente las operaciones de extracción, transformación y análisis de datos. Todos los resultados fueron almacenados en su mayoría en la Geodatabase TFM\_Geotermia.gdb

Se trabajó con el shapefile de gradientes del SGC (más robusto que CSV para mantener tipos y dominios). El dataset llega en coordenadas geográficas WGS 84 (EPSG:4326). Para garantizar coherencia métrica con otras capas del proyecto (AOI, análisis térmico previo), se ejecutó Project a WGS 84 / UTM Zona 18N (EPSG:32618). Esta proyección se usa en todo el flujo de trabajo para que distancias, radios de búsqueda e interpolaciones queden en metros. Por conveniencia cartográfica se conservaron ambos sistemas en atributos: LATITUD/LONGITUD y EASTING/NORTHING.

Con Export Features de ArcGIS Pro y el Field Map se seleccionaron solo los campos relevantes para el TFM, eliminando duplicados en unidades inglesas y metadatos no usados. Se retuvieron como núcleo los datos base que consistieron en la feature class Gradiente\_SGC\_WGS84\_Clean de la geodatabase TFM\_Geotermia.gdb, conteniendo 98 puntos de medición con campos de UWI, nombre de pozo, coordenadas, elevación, temperatura superficial (TEMPERATUR), temperatura de fondo de pozo (BHT\_OC\_), profundidad (PROFUNDI\_2), gradiente geotérmico calculado (GRADIENT\_1) y flujo de calor estimado (Q\_mWm2). Se efectuó un proceso riguroso de depuración de atributos.

En esta parte del proyecto se implementó Fourier de manera explícita por simplificación de los cálculos. En estudios más profundos se debería disponer de un mapa litológico y estimar  $\lambda$  para reducir la incertidumbre. De esta forma se asumió una conductividad térmica constante de  $2.5 \text{ W/m}\cdot\text{K}$ , que es el valor representativo de rocas sedimentarias saturadas y siliciclásticas, y se asumió que Orito tiene esa formación (rango típico  $1.5\text{--}3.5 \text{ W}\cdot\text{m}^{-1}\cdot\text{K}^{-1}$ ; Clauser y Huenges, 1995). Esto se usó para el cálculo del flujo de calor mediante la ecuación:

$$\text{Flujo de Calor} = \text{Gradiente} \times \text{Conductividad Térmica}$$

La fase inicial de control de calidad incluyó la verificación de cálculos mediante la fórmula fundamental:

$$\text{Gradiente } (^\circ\text{C/km}) = [(\text{BHT} - \text{Temperatura Superficial}) / \text{Profundidad}] * 1000$$

En términos de control de calidad, se revisaron rangos y unidades para determinar de forma inicial la credibilidad de los datos, definiendo los siguientes parámetros:

- GRADIENT\_1 esperado entre  $10\text{--}40 \text{ }^\circ\text{C/km}$  para cuencas foreland; valores negativos o  $>60$  se marcan como atípicos y se revisan contra AÑO\_DE\_AC, PROFUNDI\_2 y notas (Bullard corrections, BHT vs. temperatura de formación).

- $Q_m$ Wm<sup>2</sup> esperado entre 50–100 mW/m<sup>2</sup> con  $\lambda=2.5$ .  
Se calcularon estadísticas rápidas (*Describe y Summary Statistics*) y se inspeccionaron outliers en el mapa.

Esta verificación identificó un error significativo en el pozo CARIBE-2, donde el gradiente reportado de 5.03°C/km fue recalculado a 16.47°C/km, siendo posteriormente excluido del análisis mediante la herramienta Select, que creó una nueva capa con 97 puntos válidos.

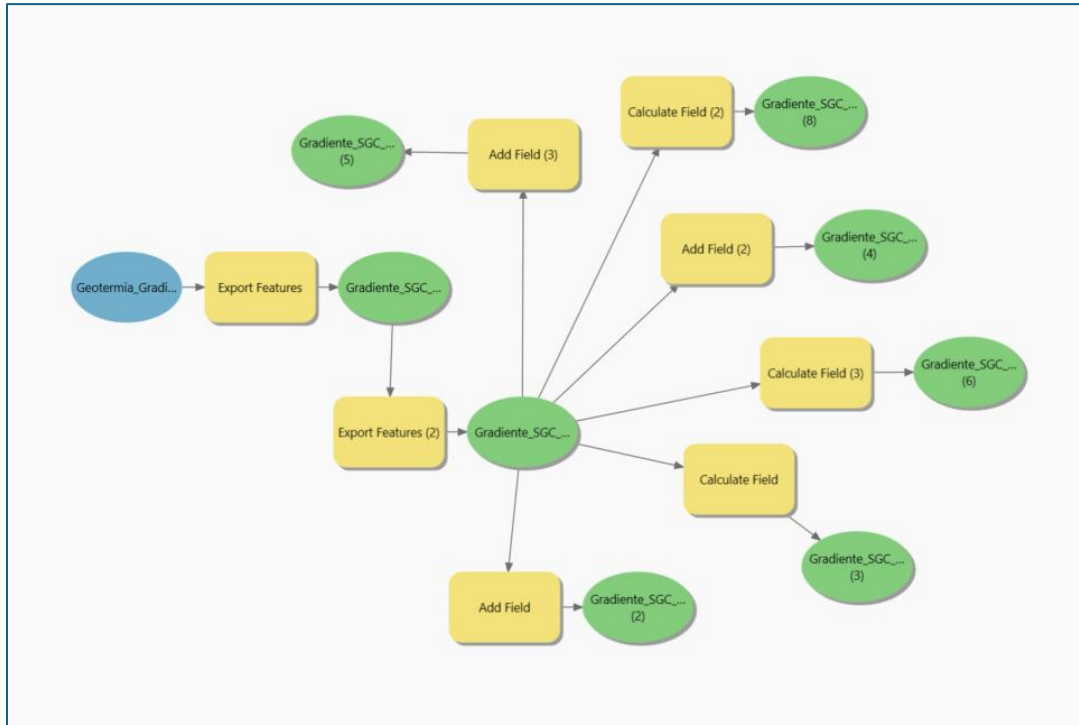
El análisis estadístico exploratorio (EDA) empleó la herramienta Summary Statistics para obtener medidas descriptivas (mínimo, máximo, media, mediana, desviación estándar). Se generaron histogramas de distribución mediante la pestaña Data de la tabla de atributos, diagramas de caja (Box Plots) a través de View > Charts > Create Chart > Box Plot para identificación de outliers, y gráficos de dispersión (Scatter Plots) para evaluar relaciones entre variables, particularmente entre profundidad y temperatura (BHT\_\_OC\_ vs PROFUNDI\_2), y profundidad y gradiente (GRADIENT\_1 vs PROFUNDI\_2).

Para el análisis espacial, se implementó Optimized Hot Spot Analysis (Getis y Ordi, 1992) para identificar clusters estadísticamente significativos de valores altos (Hot Spots) y bajos (Cold Spots) de gradiente geotérmico. La herramienta determinó automáticamente la distancia óptima de análisis mediante evaluación de la intensidad de clustering a distancias crecientes.

Finalmente, para el análisis de interpolación espacial, en una primera aproximación, se aplicó el método determinístico IDW (Inverse Distance Weighting), el cual resultó útil para visualizar la distribución general de los gradientes, pero mostró limitaciones al no capturar adecuadamente la estructura espacial ni permitir cuantificar la incertidumbre. Posteriormente, se probó el **Kriging ordinario**, pero este presentó problemas de ajuste debido a la no estacionariedad y al muestreo clusterizado de los datos, lo que redujo la confiabilidad de los resultados. De esta forma, se adoptó Kriging Bayesiano Empírico (EBK- Geostatistical Analyst, ArcGIS Pro) porque incorpora la incertidumbre de los parámetros del semivariograma mediante simulaciones y construye modelos locales sobre subconjuntos solapados, lo que permite manejar no estacionariedad moderada, anisotropía y muestreo clusterizado. La calibración del modelo se evaluó con validación cruzada, buscando error medio cercano a cero, RMS mínimo y RMS estandarizado próximo a 1.

También el EBK se ejecutó con vecindad de búsqueda local y estimación automática del semivariograma por subconjuntos; se verificó la necesidad de transformación y la presencia de anisotropía. Los mapas finales reflejan la incertidumbre mediante errores estándar y percentiles de predicción, adecuados para discutir variaciones térmicas espaciales. El EBK mostró mejor ajuste y predicciones más coherentes espacialmente que el Kriging ordinario, por lo que se utilizó para estimar tanto el gradiente geotérmico como el flujo de calor sobre el área de estudio. Se realizó validación cruzada para evaluar la precisión del modelo.

## 9.2 Resultados y Análisis de Gradientes Geotérmicos



Gráfica 42. Model Builder – Procesado de Gradientes Geotérmicos

fuelle: Autor


### Análisis Estadístico Descriptivo

Los resultados del análisis estadístico revelaron una distribución heterogénea de los gradientes geotérmicos en la cuenca del Putumayo.

Tabla 10: Estadísticas descriptivas del gradiente geotérmico y flujo de calor.

Estadístico	Gradiente (°C/km)	Flujo de Calor (mW/m <sup>2</sup> )
Mínimo	5.03	12.58
Máximo	52.37	130.93
Media	28.05	70.13
Mediana	27.43	68.16
Desviación Estándar	8.2	-
Recuento (n)	98	98


Gráfica 43: Histograma de distribución de los valores de gradiente geotérmico (GRADIENT\_1).  
Fuente: Autor



Análisis: El histograma mostró una distribución unimodal ligeramente sesgada a la derecha. La mayoría de los valores se concentran entre 19°C/km y 38°C/km, con un pico alrededor de 28-33°C/km. La cola derecha extendida hacia valores superiores a 40°C/km confirma la presencia de anomalías térmicas positivas aisladas pero significativas.


#### Identificación y Análisis de Outliers

Gráfica 44: Diagrama de Caja (Box Plot) mostrando la distribución de GRADIENT\_1 e identificando valores outliers. Fuente: Autor




Análisis: El diagrama de caja identificó múltiples outliers estadísticos. Los valores extremos altos más significativos fueron ORITO-60 (52.37°C/km) y ORITO-99 (52.35°C/km). El valor extremo bajo fue CARIBE-2 (5.03°C/km), que tras la verificación fue identificado como un error de cálculo (valor correcto ~16.47°C/km) y posteriormente excluido para análisis espaciales. El rango intercuartílico (IQR) se situó entre aproximadamente 23°C/km (Q1) y 32°C/km (Q3) Análisis de Relaciones entre Variables

Gráfica 45. Gráfico de dispersión (Scatter Plot) de temperatura de fondo de pozo (BHT\_\_OC\_) vs. profundidad (PROFUNDI\_2). Fuente: Autor



Análisis: Este gráfico mostró una fuerte correlación positiva ( $R^2 = 0.798$ ). La ecuación de tendencia lineal  $y = 32.316 + 0.02003x$  indica que la temperatura aumenta con la profundidad según un gradiente regional de aproximadamente 20.03°C/km, confirmando el principio fundamental de la geotermia.

Gráfica 46: Gráfico de dispersión (Scatter Plot) de gradiente geotérmico (GRADIENT\_1) vs. profundidad (PROFUNDI\_2).



Análisis: Este gráfico mostró muy baja correlación ( $R^2 = 0.14$ ), indicando que el gradiente geotérmico es independiente de la profundidad de medición. Este hallazgo crucial sugiere que los controles del gradiente son predominantemente geológicos (litología, estructuras, flujos de fluidos) y no puramente termodinámicos.

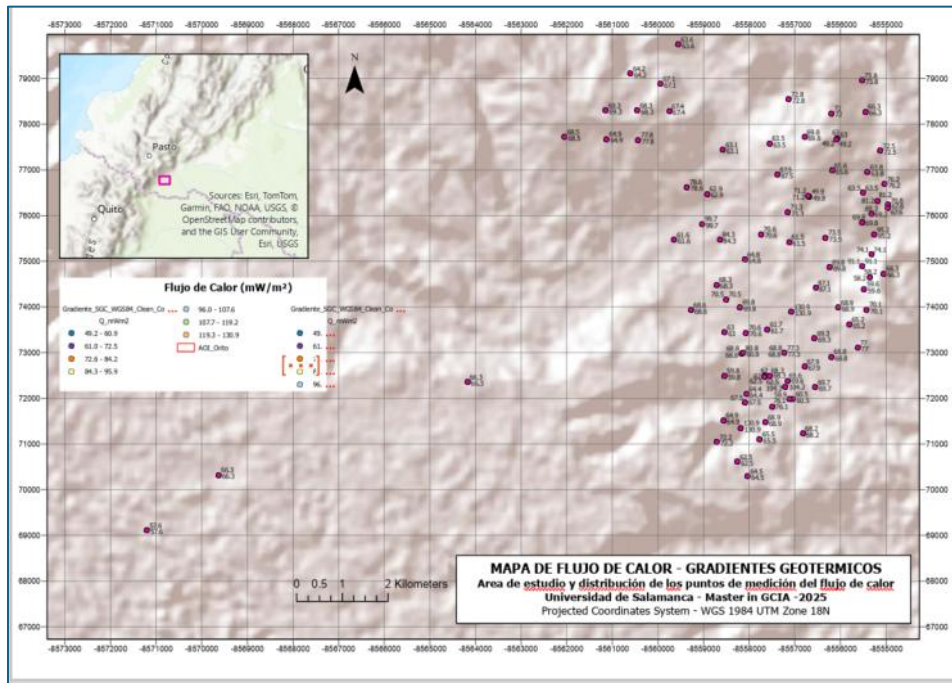
Análisis Espacial y Hot Spot Analysis

El Optimized Hot Spot Analysis se ejecutó dos veces: primero con todos los datos y luego excluyendo el punto erróneo CARIBE-2.

Tabla 11: Comparativa de resultados del Hot Spot Analysis.

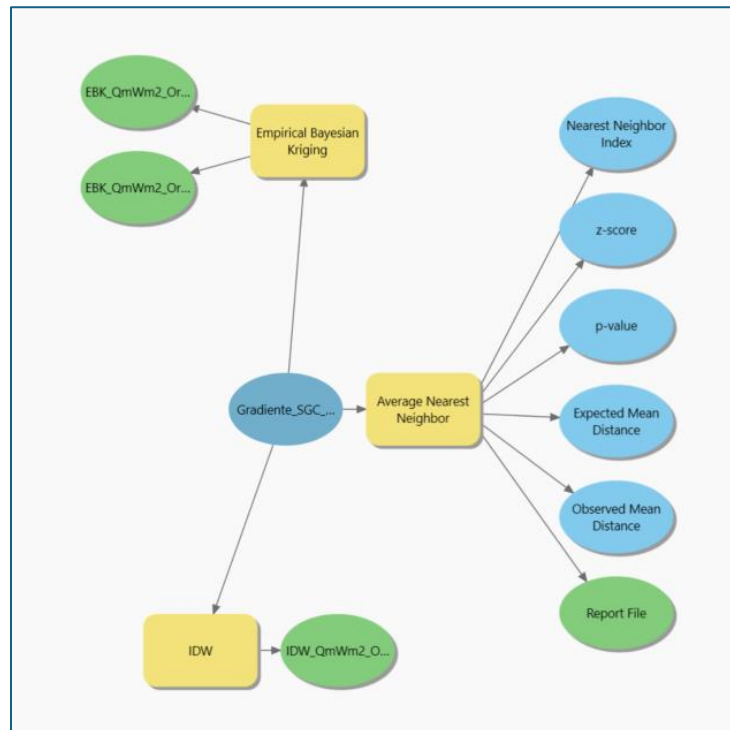
Parámetro	Con CARIBE-2	Sin CARIBE-2 (97 puntos)
Distancia óptima	3154 m	1334 m
Desviación Estándar	8.2	5
Cold Spots (99% conf.)	2	0
Hot Spots (99% conf.)	0	0
Puntos con <8 vecinos	8.20%	30.90%

Gráfica 47: Mapa de resultados del Optimized Hot Spot Analysis mostrando la distribución de los puntos.



Análisis: El resultado más importante fue la ausencia de Hot Spots estadísticamente significativos. A pesar de la presencia de valores altos aislados (ORITO-60, ORITO-99), estos no forman clusters espaciales significativos. La reducción en la desviación estándar al excluir el error y el alto porcentaje de puntos con pocos vecinos (30.9%) confirman que los datos están espacialmente dispersos y que las anomalías térmicas son locales y aisladas.

Grafica 47: Interpolación y Mapa de Gradientes fuente: Autor



Análisis:

IDW (Inverse Distance Weighting)

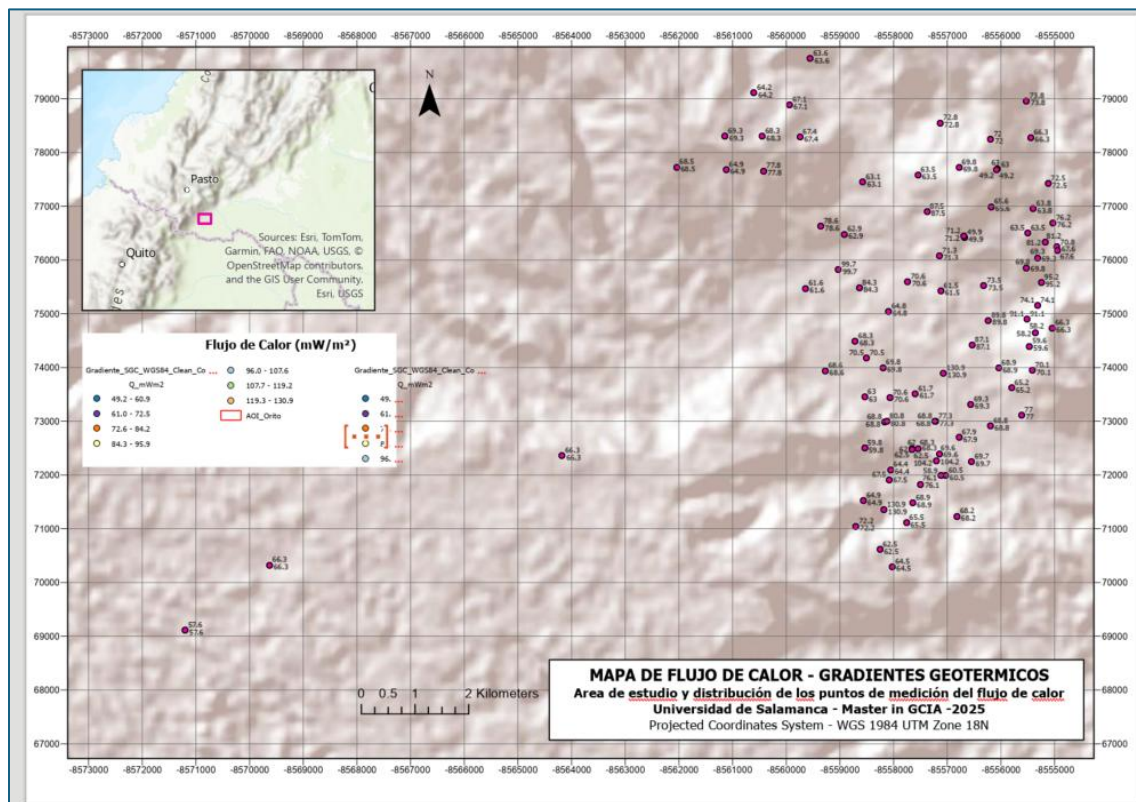
- Produjo una superficie suavizada, donde los valores altos se concentraban rígidamente alrededor de los puntos de muestreo.
- Limitaciones: no capturó la variabilidad regional ni las transiciones graduales.
- Validación cruzada:

Error Medio (ME): +0,12 (ligeramente sesgado al alza).

Raíz del Error Medio Cuadrático (RMS):  $\approx 18,5$  °C/km.

RMS estandarizado: 1,34 (indica sobre/infraestimación en algunas áreas).

Esta interpolación se considera útil como mapa exploratorio, pero sin capacidad predictiva robusta.



Gráfica 48: Mapa de interpolación de gradientes geotérmicos mediante Kriging .

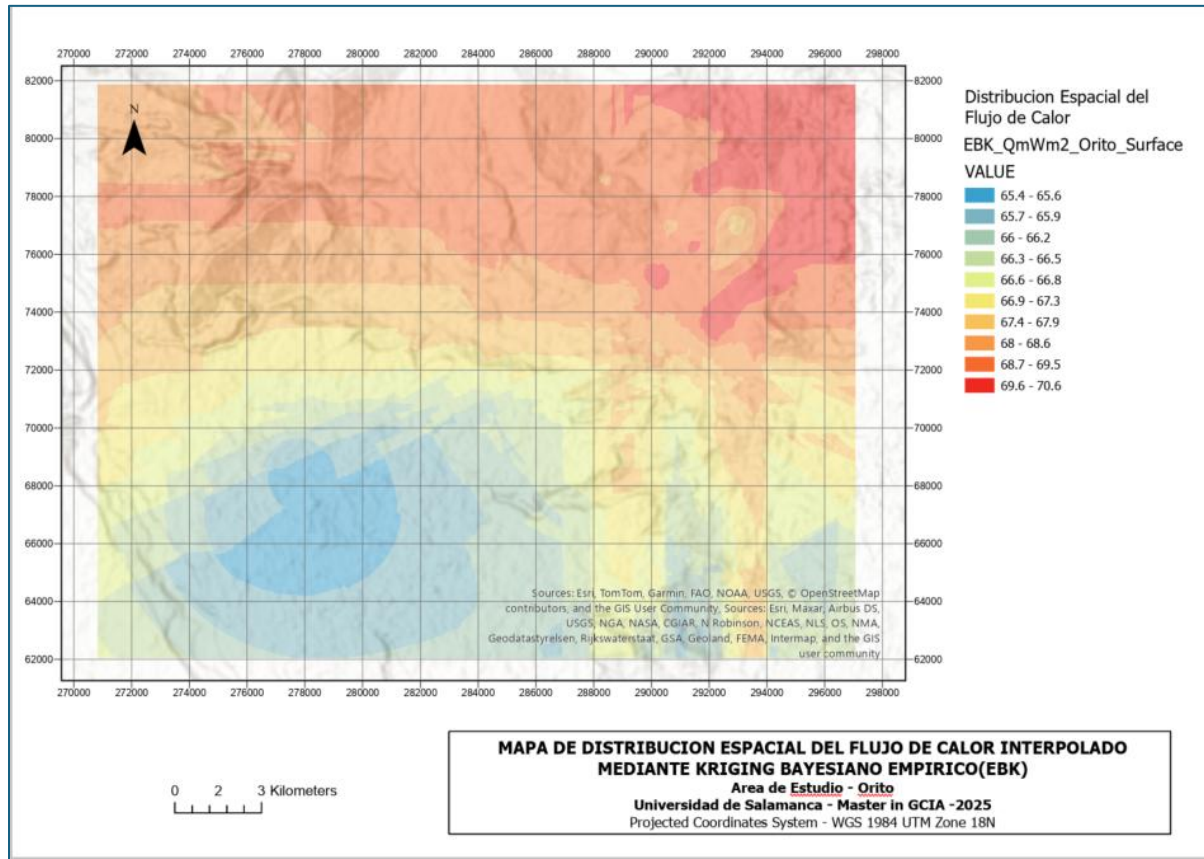
### Kriging Bayesiano Empírico (EBK)

- Generó una superficie más realista, con transiciones continuas y zonas de incertidumbre claramente definidas.
- Capturó la heterogeneidad espacial mejor que IDW, sobre todo en áreas intermedias donde no había puntos de control directo.
- Validación cruzada:

Error Medio (ME):  $\approx 0,00$  (prácticamente sin sesgo).

RMS:  $\approx 12,7$  °C/km (más bajo que IDW).

RMS estandarizado: 0,98 (muy cercano a 1, lo que indica buena calibración de varianza).



Gráfica 49: Mapa de interpolación de gradientes geotérmicos mediante Kriging .

### Calidad estadística

IDW mostró un RMS elevado ( $\approx 18,5$  °C/km), lo que significa que la dispersión de los errores fue considerable. El RMS estandarizado  $> 1$  (1,34) confirma que el modelo subestima la varianza de los datos, es decir, no refleja adecuadamente la heterogeneidad del subsuelo. El sesgo positivo (ME  $\approx +0,12$ ) indica que las estimaciones tienden a sobrevalorar ligeramente el gradiente.

EBK, en cambio, alcanzó un RMS mucho menor ( $\approx 12,7$  °C/km) y un RMS estandarizado  $\approx 1$  (0,98), lo que implica que las predicciones están bien calibradas con respecto a la variabilidad observada. Además, el sesgo es prácticamente nulo (ME  $\approx 0,00$ ), por lo que no se aprecian desviaciones sistemáticas.

IDW generó superficies muy dependientes de la localización de los puntos de muestreo. Esto produjo islas rígidas de valores altos o bajos que coincidían casi exactamente con la distribución de gradientes, sin reflejar procesos geológicos continuos.

EBK, en contraste, ofreció superficies más suaves y realistas, donde los gradientes no se limitan a reproducir los puntos, sino que muestran transiciones graduales entre zonas calientes y frías. Además, la incorporación de la incertidumbre espacial permite identificar áreas donde la predicción es menos confiable (zonas periféricas con pocos datos).

Con IDW, la interpretación geológica se vio limitada: los clusters de gradiente parecen coincidir únicamente con los sitios de perforación, lo que puede inducir a conclusiones erróneas sobre la extensión de anomalías térmicas.

Con EBK, las anomalías aparecieron como patrones regionales más coherentes, lo que facilita, aunque no se hizo en este proyecto, la correlación con estructuras tectónicas, litología y posibles sistemas hidrotermales. La posibilidad de evaluar la incertidumbre añade un valor extra para la toma de decisiones en exploración geotérmica.

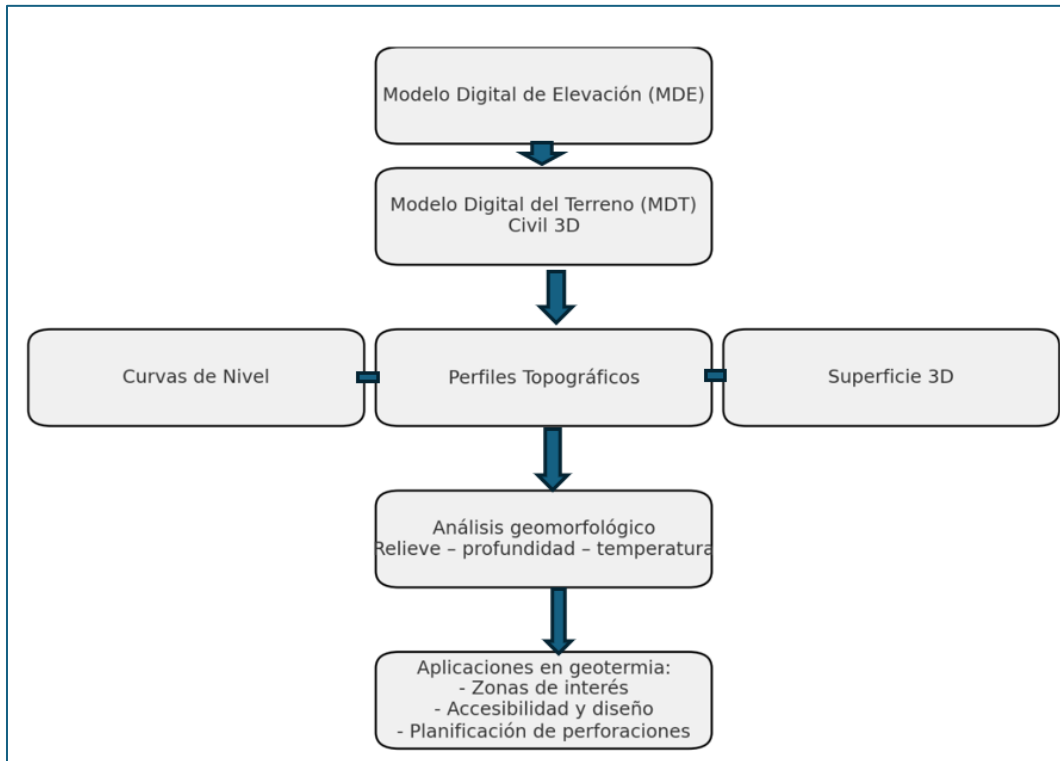
El contraste entre ambos métodos refuerza que los enfoques determinísticos (IDW) son útiles en fases exploratorias rápidas, pero no ofrecen control sobre la incertidumbre. Los métodos geostatísticos avanzados realizados con las herramientas de ArcGIS Pro, como EBK permiten no solo estimar valores, sino también modelar la confiabilidad de la predicción, aspecto clave cuando se trata de planear perforaciones, inversiones o priorizar zonas de exploración.

El uso de EBK se justifica plenamente frente a IDW y Kriging ordinario. El primero (IDW) resultó demasiado dependiente de los puntos de muestreo y con errores más altos, mientras que EBK proporcionó mejor ajuste estadístico, continuidad espacial y mapas de incertidumbre, lo cual es esencial para caracterizar el gradiente geotérmico y el flujo de calor en Orito de manera confiable.

## **11.0 MDE, MDT y Tecnologías CAD**

### **11.1 Importancia del MDE en Civil 3D y los Productos Derivados**

El Modelo Digital de Elevación (MDE) constituye la base fundamental para cualquier análisis topográfico y geoespacial, ya que representa la superficie terrestre en formato tridimensional. En el contexto del estudio del potencial geotérmico en Orito (Putumayo), la incorporación del MDE en Autodesk Civil 3D adquiere un valor especial, pues este software permite transformar la información raster en un modelo vectorial preciso, conocido como Modelo Digital del Terreno (MDT) o superficie.



Gráfica 50: Esquema conceptual del flujo de trabajo en Civil 3D fuente: Autor

El esquema conceptual del flujo de trabajo en Civil 3D, que muestra la derivación del Modelo Digital de Elevación (MDE) hacia productos como el MDT, las curvas de nivel y los perfiles topográficos, fue aplicado parcialmente al análisis geotérmico en Orito (Putumayo).

### 11.2 Metodología Integración SIG - CAD

- Descarga y preparación del MDE

Se descargó el Modelo Digital de Elevación (MDE) correspondiente al municipio de Orito (Putumayo), garantizando su resolución adecuada y consistencia espacial. Este insumo raster fue verificado en cuanto a sistema de referencia para asegurar compatibilidad con las demás capas del proyecto.

- Importación en Autodesk Civil 3D

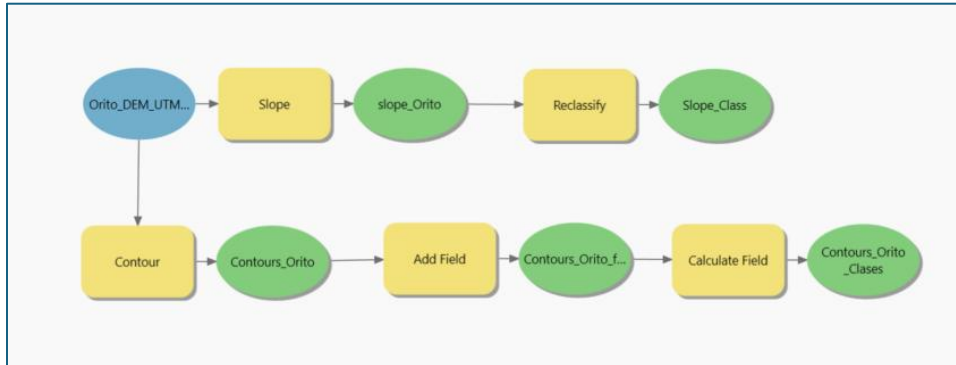
El MDE fue cargado en Civil 3D y transformado en un Modelo Digital del Terreno (MDT), representado como una superficie vectorial precisa. Esta conversión permitió trabajar en un entorno de ingeniería, orientado al modelado 3D y al diseño de superficies.

- Se emplearon las herramientas Toolspace de Civil 3D para importar los gradientes y asignar el sistema de coordenadas al dibujo CAD.


### 11.3 Resultados y Generación de productos derivados

Se creó un Model Builder para automatización y procesamiento del MDE.

Gráfica 51: Procesamiento MDE fuente: Autor

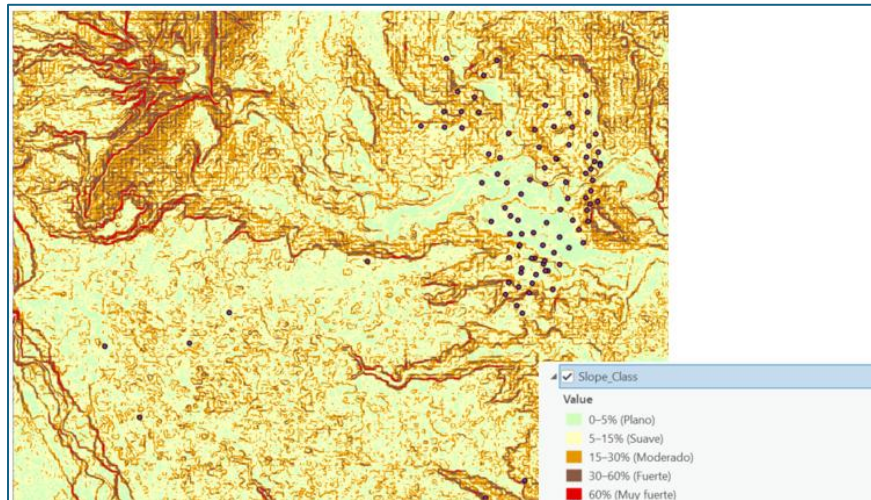


Gráfica 52: Modelo Digital de Elevación - MDE Orito fuente: Autor



El modelo hipsométrico revela que los gradientes analizados se concentran entre los 500 y 1500 m de altitud, con algunos puntos aislados en cotas más bajas hacia el suroccidente. Esta franja altitudinal coincide con la zona de transición entre el piedemonte amazónico y los primeros relieves andinos, un entorno donde la topografía intermedia favorece tanto la acumulación de aguas subterráneas como la circulación de fluidos geotermales. El contraste altitudinal también permite relacionar los gradientes con estructuras tectónicas locales que controlan la distribución de temperaturas en profundidad.

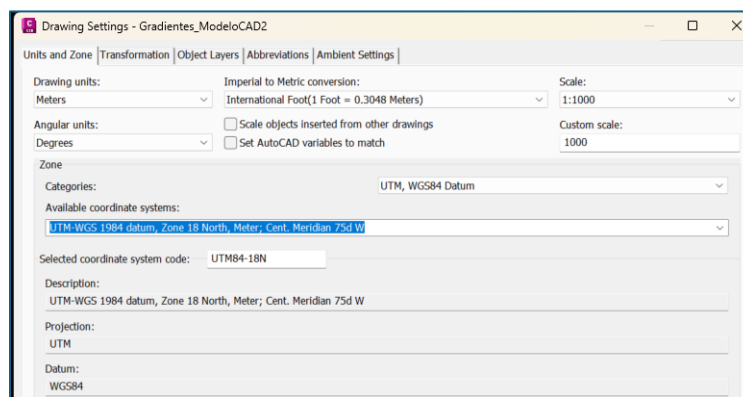
Gráfica 52: Pendientes - Slope - MDE Orito fuente: Autor




La clasificación de pendientes evidencia que gran parte del área de Orito se caracteriza por relieves planos a suaves (0–15 %), principalmente en el valle central y zonas bajas. Sin embargo, hacia las laderas y bordes montañosos se concentran pendientes moderadas a fuertes (15–60 %) e incluso muy fuertes (>60 %), lo que indica áreas con mayor inestabilidad geomorfológica y restricciones para la accesibilidad. La distribución de los puntos de gradiente geotérmico mostró que muchos de ellos se ubican en zonas de pendiente intermedia.

#### Georreferenciación y compatibilidad

Todo el procesamiento se realizó en el sistema UTM WGS84 Zona 18N, lo que garantizó la correcta georreferenciación y compatibilidad con los datos generados en ArcGIS. Se creó un Model Builder para la transformación. El trabajo en un sistema proyectado permitió integrar de manera coherente la información proveniente de diferentes fuentes (SGC, ArcGIS Pro), generando un marco espacial común para el análisis.



Gráfica 53: configuración del sistema de Coordenadas en CAD fuente: Autor



Gráfica 54: Localización de los gradientes en Civil 3D- Geolocation tool      fuente: Autor

La transformación del MDE a MDT en Civil 3D permitió una visualización tridimensional más precisa que en entornos SIG convencionales. Las curvas de nivel obtenidas facilitaron la identificación de áreas con pendientes críticas y de posibles corredores de inestabilidad geomorfológica relevantes para la planificación de perforaciones.


Los perfiles topográficos aportaron una visión bidimensional de la variación altitudinal, lo cual fue clave para correlacionar la posición de gradientes geotérmicos con el relieve y discutir su relación con la profundidad de los pozos.

En el contexto del TFM, la principal ventaja de Civil 3D fue vincular el análisis geoespacial con un entorno de modelado ingenieril aplicado a la geotermia, donde el MDT y sus derivados se convierten en herramientas útiles no solo para la descripción, sino también para escenarios de simulación constructiva y planificación estratégica.

La creación del MDT en Civil 3D permitió una visualización y un análisis más dinámicos de la topografía respecto a otros entornos SIG. Civil 3D está orientado al modelado y diseño de infraestructuras, por lo que su motor gráfico y de cálculo facilita la generación de productos como:

- Curvas de nivel, derivadas directamente del MDT, que permiten analizar con claridad la morfología del terreno, identificar pendientes críticas y reconocer áreas con mayor o menor estabilidad geomorfológica.
- Perfiles topográficos, generados a partir de líneas de corte sobre el MDT, que ofrecen una representación bidimensional de la variación altitudinal en función de la distancia horizontal. Estos perfiles son fundamentales para relacionar la ubicación de los gradientes geotérmicos con la topografía superficial y estimar posibles correlaciones entre relieve, profundidad de perforaciones y temperatura.

El uso de Civil 3D aporta además un componente de precisión ingenieril, ya que permite trabajar en un sistema de coordenadas proyectado (en este caso, UTM WGS84 Zona 18N), garantizando que las superficies, curvas de nivel y perfiles estén correctamente georreferenciados y sean compatibles con los datos provenientes de ArcGIS Pro. Esto asegura que la integración de información como puntos de gradiente, profundidades y flujos de calor se realice en un mismo marco espacial.



Gráfica 55: Generación Modelo digital de Terreno en Civil 3D      fuente: Autor

En el contexto del TFM, la importancia de mostrar el MDE en Civil 3D radica en la posibilidad de conectar el análisis geoespacial con un entorno de diseño y modelado 3D aplicado a la ingeniería. De esta manera, el MDT, las curvas de nivel y los perfiles no solo cumplen una función descriptiva y analítica, sino que también se convierten en herramientas aplicables a escenarios de planificación de perforaciones, estudios de accesibilidad e incluso simulaciones constructivas para proyectos de aprovechamiento geotérmico.

## 12.0 Discusiones, conclusiones y Recomendaciones

A través del presente Trabajo de Fin de Máster se pretendía evaluar el potencial geotérmico de Orito (Putumayo) mediante la integración de herramientas SIG, Google Earth Engine y software CAD, con el fin de analizar de manera conjunta la temperatura superficial, el gradiente geotérmico y el flujo de calor. Los resultados alcanzados permiten afirmar que sí existe relación entre los gradientes medidos y las variables derivadas de teledetección, lo que aporta evidencia útil para comprender la dinámica térmica de la región. Es importante decir que hay otras variables que se deben considerar y que no están al alcance de este trabajo, tales como los estudios de geotecnia y trabajo de campo, por ejemplo.

El desarrollo metodológico demostró que el uso de geotecnologías constituye una estrategia eficaz y transferible para el estudio y modelado de gradientes térmicos, aportando productos concretos como mapas temáticos, interpolaciones geoestadísticas y modelos 3D aplicables a escenarios de exploración. Sin embargo, uno de los principales problemas identificados fue la falta de información confiable y homogénea, tanto en la cobertura de registros de gradientes como en la calidad de los datos disponibles. Este aspecto se explica en parte por la localización de Orito en una zona selvática del sur de Colombia, donde las condiciones de accesibilidad, logística y disponibilidad de estudios sistemáticos limitan la densidad de información geotérmica.

Aún con estas limitaciones, se cumplió el objetivo central del trabajo: demostrar que las geotecnologías constituyen un soporte valioso y transferible para el estudio de gradientes térmicos, permitiendo generar productos aplicables como mapas temáticos, interpolaciones avanzadas y modelos 3D. Estos resultados representan un aporte metodológico que puede ser replicado en otras regiones de Sudamérica con condiciones similares, donde la escasez de datos hace aún más relevante la integración de SIG, teledetección y modelado CAD para la exploración geotérmica.

Los resultados demuestran que el potencial geotérmico de la cuenca del Putumayo se caracteriza por anomalías térmicas locales y no por sistemas regionales extensos. La paradoja de tener puntos calientes (valores altos) pero no Hot Spots (clusters estadísticos) se explica por la naturaleza aislada de estas anomalías. ORITO-60 y ORITO-99, con gradientes de  $52,37^{\circ}\text{C}/\text{km}$  y  $52,35^{\circ}\text{C}/\text{km}$  respectivamente, representan los objetivos más promisorios para exploración detallada, particularmente considerando sus profundidades someras (580 m y 809 m respectivamente) que favorecen la viabilidad económica de proyectos geotérmicos.

La independencia del gradiente respecto a la profundidad ( $R^2 = 0.14$ ) tiene implicaciones cruciales, indicando que los controles geológicos (fallas, fracturas, litología, sistemas de fluidos) dominan sobre los factores termodinámicos. Esto sugiere que la exploración debe enfocarse en identificar estructuras geológicas favorables y no solo en buscar mayores profundidades.

Los puntos ORITO-60 y ORITO-99, con gradientes excepcionales ( $\sim 52^{\circ}\text{C}/\text{km}$ ) y profundidades someras ( $< 900\text{ m}$ ), representan los objetivos más promisorios. Su carácter aislado sugiere que podrían estar asociados a sistemas de flujo de fluidos locales a través de fracturas, más que a una fuente de calor profunda extensa.

Las geotecnologías empleadas (ArcGIS Pro, ModelBuilder, análisis espacial, Civil 3D) demostraron ser herramientas poderosas y esenciales para la evaluación objetiva del potencial geotérmico, permitiendo integrar, analizar y visualizar datos espaciales complejos para la toma de decisiones informadas.

De la integración SIG-CAD se pudo determinar que la combinación de pendientes y altitud indica que los gradientes geotérmicos en Orito se concentran en un sector de topografía moderada (500–1500 m, 5–30 % de pendiente), condiciones que son relevantes para la accesibilidad de perforaciones y para la dinámica hidrogeotérmica. Esta información espacial constituye un insumo clave para planificar campañas de exploración y evaluar la viabilidad de proyectos de aprovechamiento energético.

### 13. Bibliografía

- Akinola, O. O., Akingboye, A. S., & Oyeyemi, K. D. (2021). Integration of geophysical and GIS-based analyses for geothermal resource assessment in Nigeria. *Geothermics*, 94, 102103. <https://doi.org/10.1016/j.geothermics.2021.102103>
- Chao, J., Zhao, Z., Lai, Z., Xu, S., Liu, J., Li, Z., ... Tu, Y. (2023). Detecting geothermal anomalies using Landsat 8 thermal infrared remote sensing data in the Ruili Basin, Southwest China. *Environmental Science and Pollution Research*, 30, 104726. <https://doi.org/10.1007/s11356-023-29678-0>
- Davies, J. H., & Davies, D. R. (2010). Earth's surface heat flux. *Solid Earth*, 1(1), 5–24. <https://doi.org/10.5194/se-1-5-2010>
- Fernández, M., Torne, M., Vergés, J., & Gómez-Ortiz, D. (2022). Lithospheric structure and geothermal gradients in NW Iberia: Implications of subduction–collision processes. *Tectonophysics*, 836, 229401. <https://doi.org/10.1016/j.tecto.2022.229401>
- González, A., & Rodríguez, J. (2020). 3D resistivity characterization of the Paipa geothermal system (Colombia) using magnetotelluric data. *Journal of South American Earth Sciences*, 104, 102878. <https://doi.org/10.1016/j.jsames.2020.102878>
- González, D., & Rodríguez-Gonzálvez, P. (2019). Integrated remote sensing and GIS-based approaches for geothermal potential mapping in Spain. *Renewable Energy*, 136, 798–810. <https://doi.org/10.1016/j.renene.2018.08.067>
- Li, X., Zhang, Y., Wang, J., & Chen, H. (2023). Detecting geothermal anomalies using multi-temporal LST with GEE: A case study on the Qinghai–Tibet Plateau. *Remote Sensing*, 15(12), 3067. <https://doi.org/10.3390/rs15123067>
- Martínez, J., Carrera, J., Alcalde, J., & Marzán, I. (2022). 3D geothermal mapping in Catalonia (Spain) using deep learning algorithms and borehole data. *Geothermics*, 100, 102386. <https://doi.org/10.1016/j.geothermics.2022.102386>
- Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503–510. <https://doi.org/10.1016/j.tree.2005.05.011>
- Roy, B., & Bari, E. (2022). Examining the relationship between land surface temperature and landscape features using spectral indices with Google Earth Engine. *Heliyon*, 8(10), e10668. <https://doi.org/10.1016/j.heliyon.2022.e10668>

Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2004). Land surface temperature retrieval from Landsat TM 5. *Remote Sensing of Environment*, 90(4), 434–440. <https://doi.org/10.1016/j.rse.2004.02.003>

Soszynska, A., Hewson, R., & Hecker, C. (2023, junio). Detection of geothermal anomalies using pre-dawn ECOSTRESS imagery. En *Proceedings of the 42nd EARSeL Symposium*. European Association of Remote Sensing Laboratories.

Turcotte, D. L., & Schubert, G. (2014). *Geodynamics* (3rd ed.). Cambridge University Press. <https://doi.org/10.1017/CBO9780511843877>

Witter, J. B., Trainor-Guitton, W. J., & Siler, D. L. (2019). Uncertainty and risk evaluation during the exploration stage of geothermal development: A review. *Geothermics*, 78, 233–242. <https://doi.org/10.1016/j.geothermics.2018.12.011>

Zhan, Q., Liu, F., & Zhou, Y. (2023). Identifying geothermal anomalies along volcanic faults in Southeast Asia using Google Earth Engine and geological vector data. *International Journal of Applied Earth Observation and Geoinformation*, 121, 103357. <https://doi.org/10.1016/j.jag.2023.103357>

Zhang, L., Huang, F., & Zhao, Y. (2023). Geothermal resource potential assessment using AHP and GIS in China. *Energies*, 16(7), 2851. <https://doi.org/10.3390/en16072851>

### 13. Anexos

#### Anexo 1: Base de datos de gradientes geotérmicos filtrados para Orito (Putumayo)

OBJECTID *	UWI	NOMBRE DEL	DEPARTAMEN	CUENCA	LATITUD	LONGITUD	COORDENADA	COORDENA.1	ELEVACION	TEMPERATUR	BHT_OC	PROFUNDI.2	GRADIENT.1	AÑO DE AC	K.WmK	Q.Wm2	Q.mWm2
1	CARI0001	CARIBE-1	Putumayo	Caguan-Putumayo	0.623672	-76.999694	674947.979272	560500.239825	697.6872	24.711564	71.111111	2360.0664	23.034126	2008	2.5	0.057585	57.585315
2	CARI0002	CARIBE-2	Putumayo	Caguan-Putumayo	0.600181	-77.011106	673674.625823	557899.92631	652.5768	24.937116	28.888889	2398.1664	5.033874	2008	2.5	0.012585	12.584685
3	CARI0003	CARIBE-3	Putumayo	Caguan-Putumayo	0.634592	-76.985608	676518.720012	561708.364399	604.1136	25.179432	81.111111	2419.5024	26.509668	2008	2.5	0.066274	66.27417
4	CARI0004	CARIBE-4	Putumayo	Caguan-Putumayo	0.597039	-77.017481	672963.851213	557552.452595	631.2408	25.043796	78.333333	2405.7864	25.53899	2008	2.5	0.063847	63.847475
5	CONG0001	CONGA-1	Putumayo	Caguan-Putumayo	0.652879	-76.936589	681983.47627	563730.024318	540.1056	25.499472	81.666667	2427.1224	26.536449	2008	2.5	0.066341	66.341122
6	CLDR0001	CALDERO-1	Putumayo	Caguan-Putumayo	0.725183	-76.908372	685133.134689	571733.103721	378.8664	26.305668	87.777778	2255.52	30.591966	2008	2.5	0.07648	76.479915
7	ORIT00015	ORITO SUR-1	Putumayo	Caguan-Putumayo	0.568547	-76.894417	686678.866207	554390.960674	409	26.155	86.666667	2764.2312	25.367866	2008	2.5	0.06342	63.419665
8	ORIT0010	ORITO-10	Putumayo	Caguan-Putumayo	0.713497	-76.904483	685565.756852	570439.053993	405.6888	26.171556	71.111111	2002.2312	25.680804	2008	2.5	0.064202	64.20201
9	ORIT0100	ORITO-100	Putumayo	Caguan-Putumayo	0.681961	-76.878753	688431.349499	566945.987583	350.2152	26.448924	46.111111	763.524	28.239893	2008	2.5	0.0706	70.599733
10	ORIT0101	ORITO-101	Putumayo	Caguan-Putumayo	0.686281	-76.873475	689019.836174	567423.948786	327.0504	26.564748	47.777778	815.6448	28.534031	2008	2.5	0.071335	71.335077
11	ORIT0102	ORITO-102	Putumayo	Caguan-Putumayo	0.680414	-76.873217	689048.245677	566774.341736	321.564	26.59218	45.555556	861.06	24.582649	2008	2.5	0.061457	61.456623
12	ORIT0103	ORITO-103	Putumayo	Caguan-Putumayo	0.673428	-76.857389	690811.787169	565999.916713	385.2672	26.273664	43.333333	821.7408	23.291204	2008	2.5	0.058228	58.22801
13	ORIT0104	ORITO-104	Putumayo	Caguan-Putumayo	0.688525	-76.855783	690991.690607	567671.169657	329.184	26.55408	51.111111	820.2168	32.469373	2008	2.5	0.081173	81.173432
14	ORIT0105	ORITO-105	Putumayo	Caguan-Putumayo	0.651956	-76.873958	688963.807752	563623.828205	320.04	26.5998	52.222222	652.5768	41.668231	2008	2.5	0.104171	104.170577
15	ORIT0011	ORITO-11	Putumayo	Caguan-Putumayo	0.671147	-76.859422	690696.484269	565747.505054	390.7536	26.246232	67.222222	1996.6864	23.854459	2008	2.5	0.059636	59.636147
16	ORIT0012	ORITO-12	Putumayo	Caguan-Putumayo	0.672017	-76.887528	687452.736533	565845.919855	360.2736	26.398632	76.666667	2088.7944	27.338713	2008	2.5	0.068347	68.346782
17	ORIT0013	ORITO-13	Putumayo	Caguan-Putumayo	0.654106	-76.885994	687622.510752	563862.599121	394.4112	26.227844	71.111111	2177.796	23.918261	2008	2.5	0.059796	59.795653
18	ORIT0014	ORITO-14	Putumayo	Caguan-Putumayo	0.698561	-76.886261	687595.633534	568784.247302	352.3488	26.438256	71.111111	2031.1872	25.242194	2008	2.5	0.063105	63.105485
19	ORIT0015	ORITO-15	Putumayo	Caguan-Putumayo	0.70105	-76.870186	689387.345196	569058.720319	443.1792	25.984104	76.666667	2054.352	27.929493	2008	2.5	0.069824	69.827333
20	ORIT0016	ORITO-16	Putumayo	Caguan-Putumayo	0.661458	-76.868197	689606.467639	564675.491811	334.3656	26.528172	75.555556	2003.7552	27.70449	2008	2.5	0.069261	69.261225
21	ORIT0017	ORITO-17	Putumayo	Caguan-Putumayo	0.689342	-76.869272	689488.411941	567762.462246	373.38	26.3331	45	1082.04	19.965816	2008	2.5	0.049915	49.91454
22	ORIT0018	ORITO-18	Putumayo	Caguan-Putumayo	0.645342	-76.886183	687600.918525	562892.366939	433.1208	26.034396	77.777778	2287.524	25.969108	2008	2.5	0.064923	64.92277
23	ORIT0019	ORITO-19	Putumayo	Caguan-Putumayo	0.667047	-76.892569	686890.529116	565295.771024	349.9104	26.450448	79.444444	2197.608	27.430813	2008	2.5	0.068577	68.577033

## Anexo 2: Fragmento Código Python para cálculo de interpolación

```

# coding: utf-8
# --- Correlación LST ~ NDVI/NDWI/NDBI por año (2020/2022/2024) ---
import arcpy, numpy as np, os, csv

# Tablas (en la GDB):
# 2020: r"C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\TFM.gdb\Sample_ALL_2020",
# 2022: r"C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\TFM.gdb\Sample_ALL_2022",
# 2024: r"C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\TFM.gdb\Sample_ALL_2024",
#
# Carpeta de salida (junto a la GDB):
base_dir = os.path.dirname(r"C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\TFM.gdb")
out_dir = os.path.join(base_dir, "Correlacion_LST")
os.makedirs(out_dir, exist_ok=True)

def pick_field(fields, year, key):
    """Elige el campo que contenga el año y la palabra clave (LST/NDVI/NDWI/NDBI)."""
    key = key.upper()
    cand = [f.name for f in fields if (key in f.name.upper() and str(year) in f.name)]
    if not cand:
        # plan B: sin año, buscando por palabra clave
        cand = [f.name for f in fields if key in f.name.upper()]
    if not cand:
        raise ValueError("No encontré campo para (key) (year)")
    # Si hay varios, me quedo con el primero que termine en Band_1 (si existe)
    band1 = [c for c in cand if c.upper().endswith("BAND_1")]
    return band1[0] if band1 else cand[0]

def corr_y_productos(tbl, year):
    # Detectar nombres de campos
    flds = arcpy.ListFields(tbl)
    f_LST = pick_field(flds, year, "LST")
    f_NDVI = pick_field(flds, year, "NDVI")
    f_NDWI = pick_field(flds, year, "NDWI")
    f_NDBI = pick_field(flds, year, "NDBI")

    campos = [f_LST, f_NDVI, f_NDWI, f_NDBI]
    arr = arcpy.da.TableToNumPyArray(tbl, campos, skip_nulls=True)
    M = np.vstack([arr[c].astype("float64") for c in campos]).T

    # Filtro robusto de NoData/infinitos
    NODATA_F32 = -0.40283838
    mask = np.all(np.isfinite(M), axis=1) & np.all(M > (NODATA_F32/10), axis=1)
    M = M[mask]

    # Pearson
    corr = np.corrcoef(M, rowvar=False)
    names = ["LST", "NDVI", "NDWI", "NDBI"]

    # CSV (matriz con cabeceras)
    csv_path = os.path.join(out_dir, f"correlacion_{year}.csv")
    with open(csv_path, "w", newline="", encoding="utf-8") as f:
        w = csv.writer(f)
        w.writerow(["Year"] + names)
        for i, row in enumerate(corr):
            w.writerow([names[i]] + [f"{v:.6f}" for v in row])

```

## Anexo 3: Fragmento Código Python para cálculo de correlación (al final se usó ArcGIS Pro)

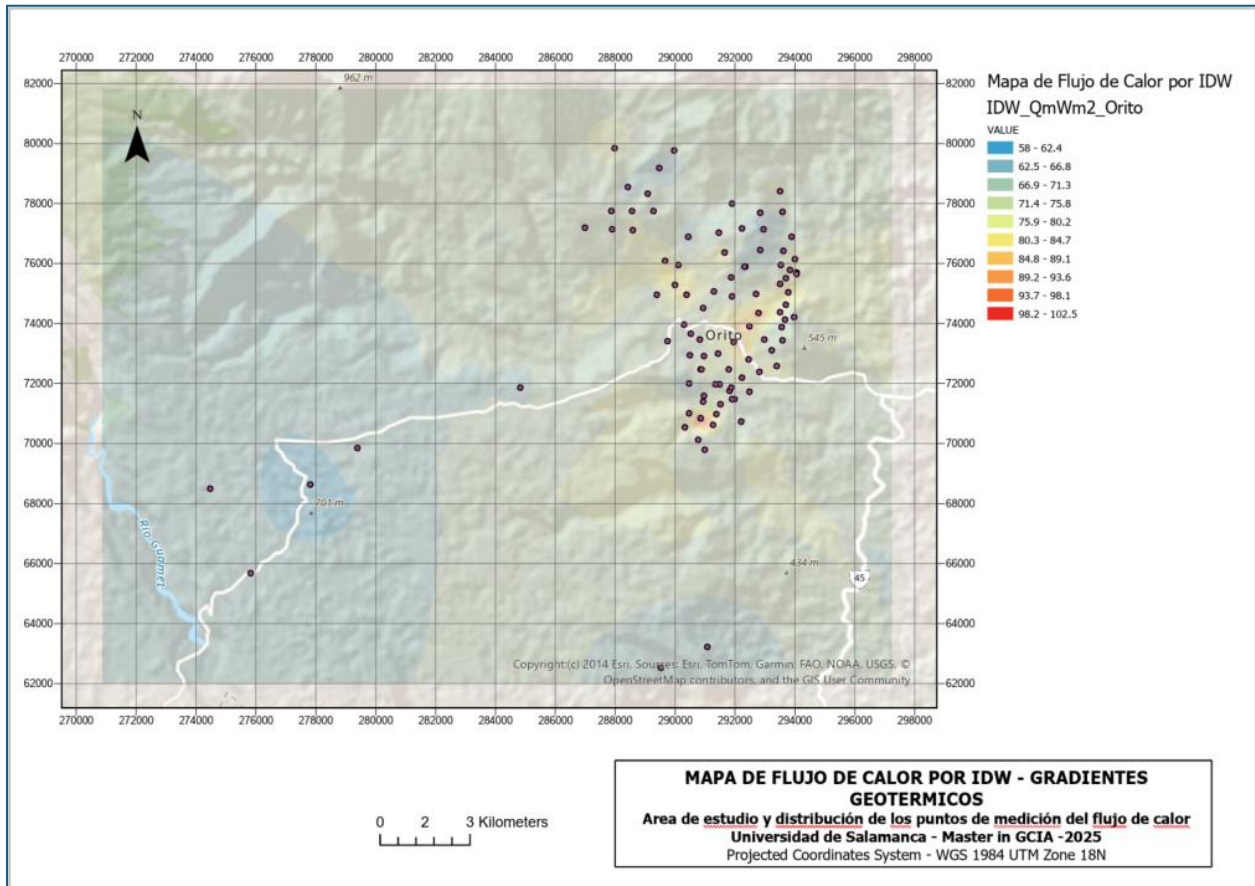
```

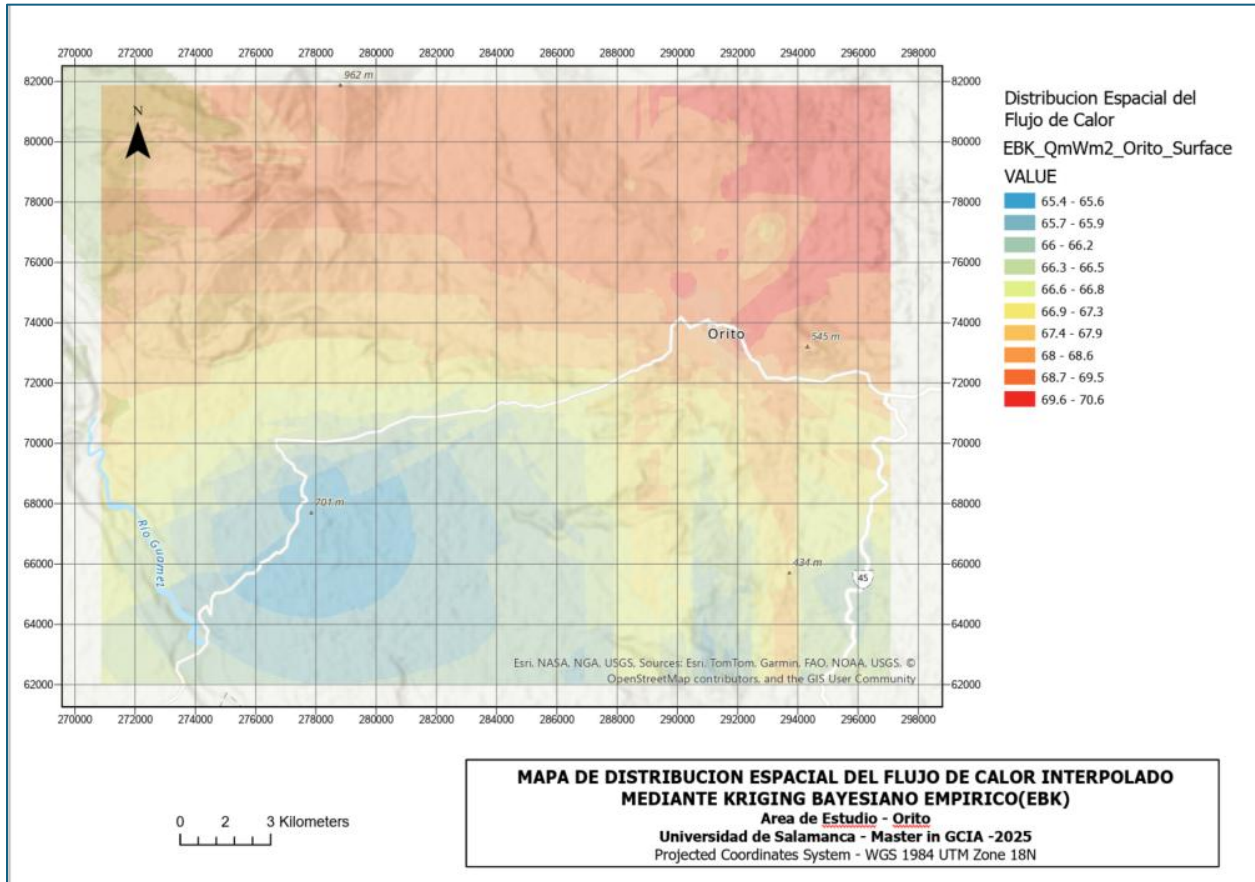
print(f"PNG en: {out_dir}")
except Exception as e:
    print(f"(Aviso) Matplotlib no disponible o falló el guardado de figuras.")
    print(e)

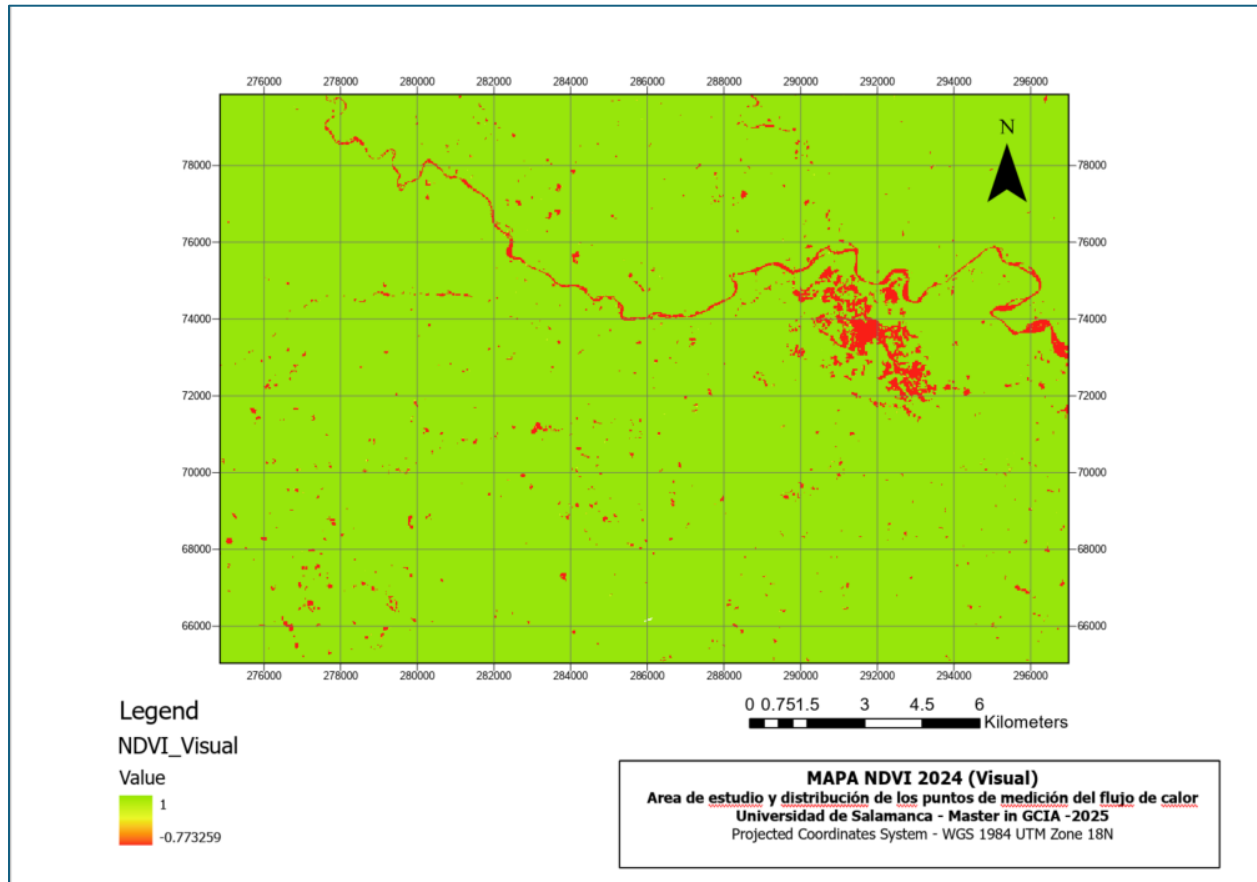
# Ejecuta para los tres años
for yr, tbl in tabs.items():
    corr_y_productos(tbl, yr)
#
# === 2020 ===
# n pixeles válidos = 549954
# Matriz de correlación (orden: LST, NDVI, NDWI, NDBI):
# [[ 1.         -0.3151  0.2938  0.3544]
#  [-0.3151  1.         -0.9775 -0.8392]
#  [ 0.2938 -0.9775  1.         0.7571]
#  [ 0.3544 -0.8392  0.7571  1.        ]]
# r(LST, NDVI) = -0.3151
# r(LST, NDWI) = 0.2938
# r(LST, NDBI) = 0.3544
# CSV: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST\correlacion_2020.csv
# PNG en: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST
#
# === 2022 ===
# n pixeles válidos = 477838
# Matriz de correlación (orden: LST, NDVI, NDWI, NDBI):
# [[ 1.         -0.4735  0.4514  0.5507]
#  [-0.4735  1.         -0.9773 -0.8493]
#  [ 0.4514 -0.9773  1.         0.7761]
#  [ 0.5507 -0.8493  0.7761  1.        ]]
# r(LST, NDVI) = -0.4735
# r(LST, NDWI) = 0.4514
# r(LST, NDBI) = 0.5507
# CSV: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST\correlacion_2022.csv
# PNG en: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST
#
# === 2024 ===
# n pixeles válidos = 509981
# Matriz de correlación (orden: LST, NDVI, NDWI, NDBI):
# [[ 1.         -0.3848  0.3827  0.4014]
#  [-0.3848  1.         -0.9744 -0.8552]
#  [ 0.3827 -0.9744  1.         0.7773]
#  [ 0.4014 -0.8552  0.7773  1.        ]]
# r(LST, NDVI) = -0.3848
# r(LST, NDWI) = 0.3827
# r(LST, NDBI) = 0.4014
# CSV: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST\correlacion_2024.csv
# PNG en: C:\Users\frank\Documents\Master USAL\TFM\2_Descarga_Analisis_de_Imágenes_Satelitales\Procesamiento de Imágenes_Sep2025\TFM\Correlacion_LST

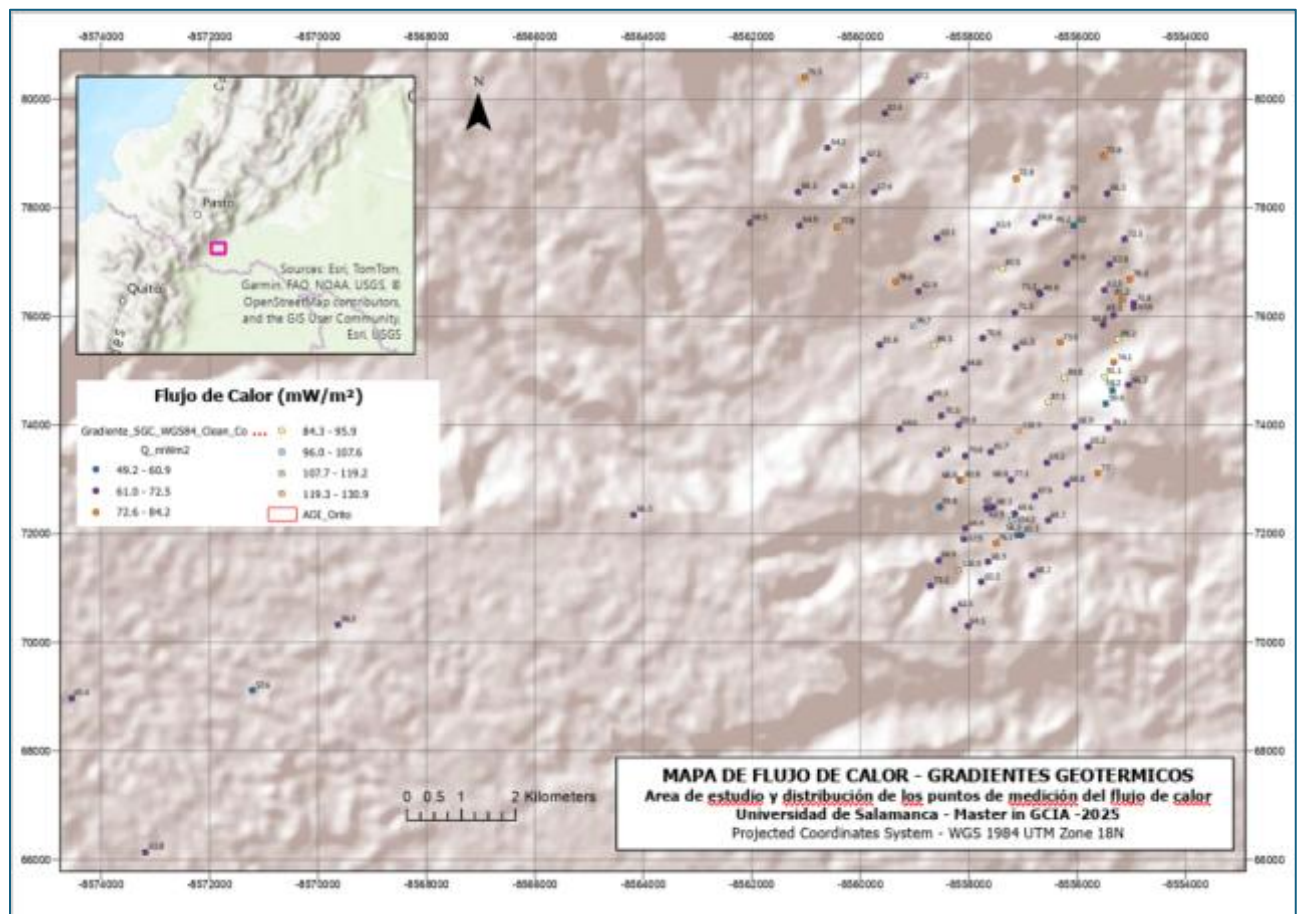
```

Anexo 4: Mapas Generados

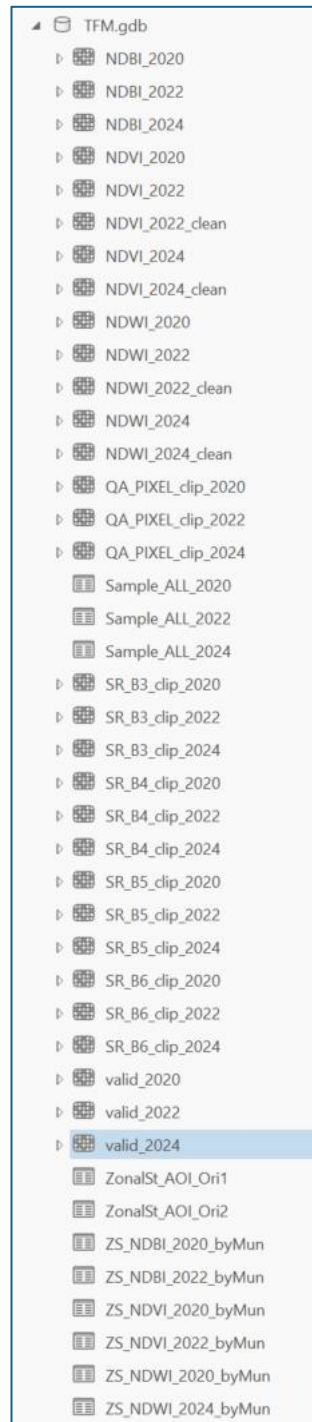
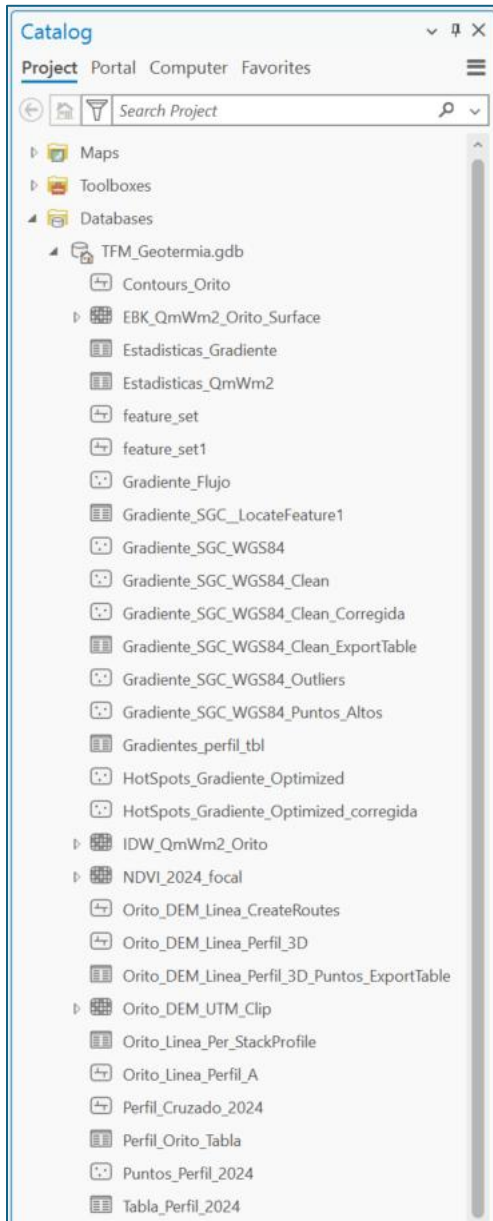








Anexo 5: Geodatabase files



Anexo 6: Nearest Neighbour Process

