

Modelo de *edge computing* a bordo de microsatélites para la susceptibilidad de incendios forestales en la zona centro y centro-sur de Chile

ROBERTO SILVA ESPINOZA

Universidad Técnica Federico Santa María
`roberto.silvae@usm.cl`

Resumen Este trabajo propone un modelo de *edge computing* a bordo de microsatélites para estimar en órbita la *susceptibilidad de ignición de incendios forestales*, entendida como la probabilidad espacial de que se produzca una ignición bajo determinadas condiciones de combustible, clima, topografía y antrópicas, y predecir incendios forestales en la zona centro y centro-sur de Chile. En el marco del proyecto SNSat de la Fuerza Aérea de Chile, se plantea una constelación de microsatélites CubeSat de 12U para procesar datos espectrales en órbita y entregar alertas operativas con baja latencia, reduciendo la transmisión de imágenes. La idea central es ubicar la computación en el borde, acercando el procesamiento a la fuente de datos y optimizando el ancho de banda de las comunicaciones terrestres.

La tesina describe la misión NGEN-MAWIDA y su arquitectura, que integra sensores electro-ópticos y capacidades de inteligencia artificial (IA) a bordo, soportadas por un SoC Xilinx Zynq-7000. El flujo de trabajo combina imágenes hiperespectrales, índices NDVI y NBR, preprocesamiento a bordo y en Tierra, y un pipeline basada en tiles de 54 km² que alimentan un CNN ligero para estimar la susceptibilidad de ignición. En operación, se estima una ventana de captura de 150 s y una latencia total inferior a 5 minutos, con alertas de 11,5 KB transmitidas en 370 ms.

La validación utiliza GMAT para ventanas de visibilidad y cobertura AOI, y MATLAB/Simulink para modelar hardware e inferencia TinyML. El trabajo evalúa la viabilidad técnica, el balance entre rendimiento y consumo de energía y las implicaciones socioeconómicas ante el cambio climático. Concluye que el *edge computing* satelital puede mejorar la toma de decisiones en terreno, reducir costos de supresión y aumentar la resiliencia operativa ante incendios.

Keywords: CubeSat · edge computing · susceptibilidad de incendios forestales · TinyML · NGEN-MAWIDA · Chile



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☐ Memoria o trabajo de título ☒ Tesis de Postgrado

Título del trabajo: " Modelo de edge computing a bordo de microsátélites para la susceptibilidad de incendios forestales en la zona centro y centro-sur de Chile "

Nombre del candidato(a): Roberto Silva Espinoza

Carrera / Grado: magister en Tecnologías de la Información

Campus: Casa Central Departamento: Departamento de Informática

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Raúl Monge, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☐ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☒ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☒ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

Contiene información técnicas de plataformas de satélites comerciales

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 29 de septiembre 2026 Firma: Raúl Monge 

Estudiante o Candidato(a):

Fecha: 29 de septiembre 2026 Firma: Roberto Silva Espinoza

1. Introducción y contexto del problema

1.1. Motivación

La Fuerza Aérea de Chile se encuentra desarrollando el proyecto Sistema Nacional Satelital (SNSat) el que dotará a Chile de capacidades estratégicas para el desarrollo de 7 microsátélites CubeSat 12U [1]. Este desarrollo consiste en el ensamblado, integración y prueba (AIT, por sus siglas en inglés) de satélites. En este contexto, se contempla la integración de tecnología nacional para el microsátélite número 7 (SNSat 7), el cual cuenta con espacio disponible para soportar una “carga útil (payload)”, elemento que define la misión espacial del satélite. Este proceso de desarrollo requiere del diseño de ingeniería y la manufactura en base a los requerimientos definidos para el estándar CubeSat [2] y el concepto de operaciones del satélite.

Desde la mirada de las nuevas misiones espaciales, y la vanguardia tecnológica para el procesamiento de datos en el espacio, la computación en el espacio, es una realidad desde 2017. A partir de misiones como “Spaceborn” de la compañía HPE:¹Space Exploration with First Ever In-Space Commercial edge computing and Artificial Intelligence ya se cuenta con una súper computadora en la Estación Espacial Internacional (ISS) dedicada a almacenar y procesar volúmenes de datos “big data” recopilados en experimentos en órbita. A la fecha, esto ha resultado en más de 24 experimentos y la ampliación de capacidades, siendo a finales del 2024 desarrollada la tercera versión del hardware.²

Con soluciones como esta, basadas en servicios *edge computing* cuya definición es trasladar la capacidad de procesamiento al borde de la red más cercanos al usuario o donde se generan los datos, se ha logrado mejorar tanto las capacidades para gestionar los recursos en órbita, como también el ancho de banda de los enlaces de comunicaciones para la transmisión de datos hacia y desde la fuente emisora. En el futuro, se espera una proyección para disponer de esta capacidad de cómputo para aplicaciones de inteligencia artificial y entre otras operaciones de alta complejidad y demanda técnica.

En contextos de cambio climático, la integración de *edge computing* con sistemas de observación remota, especialmente en satélites equipados con sensores hiperespectrales, abre una vía prometedora para la susceptibilidad de incendios forestales la cual se defina como la estimación de la probabilidad de ocurrencia de un incendio en una región [3]. Al procesar a bordo datos espectrales, se podrá identificar en tiempo real indicadores en variables determinantes y firmas espectrales del fuego, reduciendo drásticamente la demora en la toma de decisiones al contar con información más inmediata y local. Esta arquitectura donde la capacidad de procesamiento se encuentra cercana a la fuente de los datos no solo mejora la oportunidad y precisión de las alertas, sino que también optimiza el uso del ancho de banda en los canales de comunicación y permite desplegar inferencias de modelos de aprendizaje automático especializados. Así, el *edge computing* satelital se posiciona como un habilitador clave para sistemas de susceptibilidad y respuesta más rápidos y resilientes, superando las limitaciones de los enfoques tradicionales terrestres y los flujos de procesamiento centralizados.

En este contexto, el presente trabajo propone el desarrollo de un sistema de susceptibilidad de incendios forestales utilizando *edge computing* para el procesamiento de imágenes geoespaciales en órbita a bordo de un satélite CubeSat de 12U. En este sentido, la implementación de la capacidad de *edge computing* es un avance significativo respecto a los modelos tradicionales de procesamiento de datos en satélites de estándar CubeSat, lo cual implica un desafío en cuanto a la limitada disponibilidad de potencia, restricción de volumen y peso. Esto se traduce en una capacidad computacional reducida y sistemas más propensos a los efectos de la meteorología espacial.

1.2. Definición del Problema

El calentamiento global ha incrementado de forma sustantiva la aridez de los combustibles forestales a través de un mayor déficit de presión de vapor (

En bosques del oeste de EE. UU., más de la mitad del incremento observado en aridez de combustibles desde 1979 se atribuye al forzamiento antropogénico, lo que se asocia fuertemente con una mayor superficie quemada y temporadas de fuego más extensas [4]. Este mecanismo establece un vínculo

¹ <https://hewlett-packard-enterprise.prezly.com/hewlett-packard-enterprise-accelerates-space-exploration-with-first-ever-in-space-commercial-edge-computing-and-artificial-intelligence-capabilities>

² <https://www.hpe.com/us/en/collaterals/collateral.a50010159spa.html>

causal robusto entre calentamiento, aridez de combustibles y actividad de incendios, y sugiere una intensificación futura mientras los combustibles no se vuelvan limitantes [4].

Asimismo, la expansión de la interacción urbano-forestal, las igniciones antrópicas y décadas de supresión de incendios han incrementado la carga de combustible, amplificando la sensibilidad del régimen de fuego tanto a la variabilidad climática como al calentamiento antropogénico [4]. Estos factores no originan necesariamente la causa climática del problema, pero modulan dónde y cuán grandes se vuelven los eventos. El fuego, por tanto, emerge de la interacción entre forzantes climáticos y decisiones humanas de uso del suelo.

Por otra parte, desde el punto de vista socio-económico, la mayor actividad de incendios implica pérdidas de infraestructura, costos crecientes de supresión y deterioro de ecosistemas. En el caso de Chile, cuando la superficie quemada escala hasta niveles de *megaincendios*, las emisiones de CO₂ pueden alcanzar decenas de millones de toneladas. Durante 2017 se estimaron emisiones cercanas a 100 Mt CO₂, lo que comprometió metas de Contribución Determinada a Nivel Nacional (NDC) al competir con los presupuestos anuales de emisiones. El sector de uso de la tierra, cambio de uso de la tierra y silvicultura (UTCUTS) alterna entre sumidero y fuente de carbono según la magnitud de los incendios, afectando el balance nacional de gases de efecto invernadero [5].

En el contexto de la tecnología espacial, existe una brecha entre las capacidades de los productos satelitales disponibles y los requerimientos de los sistemas de alerta temprana. Las series históricas y productos de área quemada (MTBS o MODIS) son útiles para evaluar tendencias y realizar análisis *ex post*, pero no garantizan la susceptibilidad ni la proyección diaria del crecimiento del fuego. Esto limita su valor para la respuesta operativa inmediata [4].

Las fuentes revisadas no describen plataformas operativas integradas que fusionen, en tiempo cercano al real, indicadores de peligro (VPD, FWI, ERC), susceptibilidad de igniciones y observación terrestre/satelital junto con modelos de propagación y contabilidad de emisiones. Esa ausencia de integración multisensorial y de sistemas de monitoreo-modelado continuo representa la **brecha central** y limita la susceptibilidad activa y la toma de decisiones rápidas, coordinadas y eficiente en especial frente a incendios forestales de gran magnitud [4,5].

1.3. Propuesta de investigación

El presente trabajo propone la validación operacional y técnica de servicios de *edge computing* en microsátélites (SEC) para una constelación de órbita baja (LEO) y uso de inferencia de Inteligencia Artificial orientada a un modelo de susceptibilidad de ignición del fuego y descarga de alertas en tiempo real de focos de incendios forestales.

Como **Objetivo General** se ha definido; Diseñar y validar, mediante simulación, una misión satelital CubeSat 12U en órbita baja heliosíncrona que, usando *edge computing* a bordo, estime la susceptibilidad de ignición de incendios forestales en la zona centro y centro sur de Chile y genere alertas georreferenciadas en tiempo real dentro de la misma ventana de visibilidad, cumpliendo una latencia extremo a extremo menor a 5 minutos y las restricciones de potencia eléctrica, capacidad de procesamiento, memoria a bordo, enlace y ventanas de visibilidad de la plataforma.

Objetivo específico N°1 (OE1): Definir y simular el concepto de operaciones (CONOPS) y los parámetros orbitales de la misión NGEN-MAWIDA, evaluando sobre el área de interés (

Objetivo específico N°2 (OE2): Diseñar e implementar, a nivel de modelo, un pipeline de *edge computing* sobre una plataforma satelital de referencia, y estimar su desempeño en términos de tiempo de inferencia, uso de memoria, consumo de energía y volumen de datos de alertas.

Objetivo específico N°3 (OE3): Integrar los resultados orbitales y de cómputo para verificar la factibilidad operacional del servicio ECaaS, comprobando que la cadena captura, procesamiento a bordo y transmisión de alertas cumple la latencia extremo a extremo <5 minutos y se mantiene dentro del presupuesto de potencia de un CubeSat 12U.

1.4. Hipótesis y alcance

La integración de un modelo de *edge computing* a bordo de un satélite CubeSat 12U en órbita baja heliosíncrona, permite estimar en órbita la susceptibilidad de ignición de incendios forestales en la zona centro y centro sur de Chile y generar alertas georreferenciadas con latencia extremo a extremo

inferior a 5 minutos, sin vulnerar las restricciones de potencia, procesamiento, memoria y ventanas de visibilidad propias de la misión satelital.

Este trabajo corresponde a un estudio de diseño y factibilidad técnico-operacional basado en simulación para una misión satelital tipo CubeSat 12U, que abarca la definición del CONOPS y la simulación orbital en órbita baja heliosíncrona sobre un AOI entre Valparaíso y Los Lagos, el diseño de un pipeline de *edge computing* a bordo y la estimación, mediante método analítico y herramientas de simulación, de la latencia extremo a extremo, el consumo energético y el uso de memoria para verificar la viabilidad del servicio ECaaS dentro de las restricciones de un 12U; quedan fuera de alcance la implementación física del satélite, la integración hardware real de la carga útil, las pruebas en órbita y la validación empírica del desempeño del modelo de IA en un entorno operacional real.

2. Marco Teórico

2.1. Órbitas y misión satelital

En el ámbito espacial se establecen las clasificaciones de los sistemas dependiendo de la altitud y planos de sus órbitas, en este sentido podemos encontrar sistemas que van desde unos pocos kilómetros (10 km) denominados como “Low Altitude Orbit” hasta aquellos sistemas geoestacionarios a una altitud de 36.000 km de altura, estos últimos utilizados normalmente para entregar cobertura de comunicaciones a un sector delimitado de la superficie terrestre [6].

La combinación de estos sistemas, dependiendo de la aplicación, son empleados en distintas configuraciones y arquitecturas, que se conoce como constelaciones satelitales híbridas, pudiendo encontrar entre sus modos de empleo para coberturas especiales, repetidores, comunicaciones marítimas, conexiones de alta velocidad, entre otras.

El avance tecnológico, la disminución de los costos y la reducción de tamaño ha ocasionado un aumento en el interés en las redes NO terrestres para la industria y la academia; la combinación de sistemas RF/FSO [7], las plataformas a alta altura y constelaciones de satélites están siendo cada vez más utilizadas. Asimismo, la integración de estas redes con la plataforma de telecomunicaciones terrestre mediante estaciones terrenas es un modelo que está en vigencia dada la rentabilidad que presenta para los operadores de telecomunicaciones.

La arquitectura de una **misión espacial** se centra en el empleo del satélite, que es la razón de ser del viaje al espacio. Las misiones espaciales nacen de una necesidad, como la comunicación global o la monitorización de la contaminación atmosférica, entre otras aplicaciones. Entender esta necesidad es crucial para definir la misión, lo que implica establecer el objetivo, los usuarios o clientes que se beneficiarán y el concepto de operaciones de la misión definiendo el cómo interactuarán los elementos de la misión.

Un satélite es el componente central del segmento espacial de un sistema satelital y se describe típicamente como la combinación de una carga útil y un bus o plataforma que la soporta [8]. El bus debe alojar la carga útil cumpliendo restricciones de masa y volumen, y proporcionar interfaces mecánicas, térmicas, de potencia, datos y apuntamiento, así como recursos de arquitectura tales como procesamiento y memoria a bordo, enlaces de comunicación, baterías y, cuando corresponde, sistemas de propulsión para inserción orbital, mantenimiento y desorbitado [8]. En satélites pequeños, este bus integra de forma compacta subsistemas de potencia, AOCS/ADCS, telemetría, seguimiento y control (TT&C), control térmico, computadora a bordo y estructura, organizados en familias según masa y tamaño — minisatélites (100–500 kg), microsátélites (< 100 kg), nanosatélites (1–10 kg), picosatélites




Figura 1. Arquitectura híbrida satelital [6].

(0,1–1 kg) y femtosatélites (< 100 g) — caracterizadas por tiempos de desarrollo más cortos, equipos reducidos y menores costos, a menudo con redundancia limitada frente a satélites tradicionales [8].

Por otra parte, como se muestra en el Anexo A, un **CubeSat** es una clase de satélite miniaturizado basada en un formato geométrico y de masa estandarizado, introducido en 1999 por Jordi Puig-Suari (Cal Poly) y Bob Twiggs (Stanford) con el objetivo de democratizar el acceso al espacio mediante la reducción de costos y tiempos de desarrollo. Se estructura en unidades modulares llamadas “U”, típicamente de $10 \times 10 \times 10$ cm, que se ensamblan en configuraciones mayores, como el 12U, y debe cumplir estrictos requisitos de envoltorio geométrico, masa máxima y balance inercial para asegurar la compatibilidad con dispensadores comerciales, el cumplimiento normativo y la operación segura y fiable en órbita. En la Figura 8 del Anexo A, se muestran las configuraciones de 1U, 1.5U, 2U, 3U, 6U y 12U.

2.2. Sistemas Computacionales Distribuidos

Los sistemas distribuidos describen una clase de sistemas computacionales en los que los componentes de hardware y software están conectados mediante una red, y coordinan sus acciones a través del envío de mensajes con el fin de alcanzar un objetivo común [9]. Aunque los distintos paradigmas presentan comportamientos operacionales variados y utilizan diversas tecnologías, estos sistemas se definen por sus características fundamentales subyacentes y por los elementos que facilitan su funcionamiento.

Las propiedades y características de operación de sistemas distribuidos están presentes en diversos sistemas en distintos grados. La combinación de todos estos criterios identifica de manera única un sistema de procesamiento de datos distribuido [10]. En este sentido, se distinguen cinco componentes:

- **Multiplicidad** de recursos de propósito general, incluyendo componentes tanto físicos como lógicos, que pueden asignarse dinámicamente a tareas específicas. No es esencial la homogeneidad de los recursos físicos.
- **Distribución física** de estos componentes físicos y lógicos del sistema, que interactúan mediante una red de comunicaciones. (Una red utiliza un protocolo cooperativo de dos partes para controlar la transferencia de información.)
- **Un sistema operativo de alto nivel** que unifica e integra el control de los componentes distribuidos. Cada procesador individual puede tener su propio sistema operativo local, y estos pueden ser distintos.
- **Transparencia del sistema**, que permite solicitar servicios solo por nombre. El servidor no necesita ser identificado.
- **Autonomía cooperativa**, que caracteriza la operación e interacción de los recursos físicos y lógicos.

La arquitectura de sistemas distribuidos es la organización de los componentes de un software y cómo estos están segregados en distintas máquinas de la red. De este modo, esto determina la forma en que sus componentes están conectados unos con otros, cómo fluye la información que se transmite entre estos, y finalmente, en cómo estos elementos son configurados para interactuar en el sistema [11]. Las arquitecturas de sistemas distribuidos más comúnmente utilizadas son:

- Arquitectura de capas.
- Arquitecturas orientadas cliente/servidor.
- Arquitecturas de publicación y suscripción (pub/sub).

2.3. Edge Computing

La virtualización de servicios y datos en la nube ha permitido acercar los recursos al usuario de manera global, acceder a una infraestructura computacional de alto desempeño y almacenamiento masivo, servicios en la nube, redes virtuales y otros servicios de networking. El uso de la capacidad en discos duros siendo reasignados como memoria RAM permite crear una máquina virtual como si fuera un recurso físico del usuario. Esto ha logrado optimizar el uso del ancho de banda de la red y mejorar los tiempos de latencia a través de una configuración de protocolos y rutas virtuales, asimismo, agregar una etapa básica de procesamiento en los nodos más cercanos al usuario en la ruta de acceso ha mejorado sustancialmente el desempeño de la red. Asimismo, el uso de recursos computacionales

separando la funcionalidad de los segmentos de transmisión de datos de usuarios y el segmento de control de la red mediante el empleo de sistemas de telecomunicaciones que utilicen gestión de redes definidas por software (SDN) cuyo avance ha permitido la reducción significativa de la latencia de la red optimizando rutas y enlaces.

Edge computing as a Service representa la evolución del modelo **Infrastructure as a Service (IaaS)** hacia arquitecturas distribuidas en el borde de la red. Este enfoque propone que los nodos periféricos (edge nodes) no solo ejecuten tareas de procesamiento, sino que también alojen almacenamiento y cómputo cercanos al origen de los datos, mejorando la latencia y reduciendo la congestión del núcleo de red —especialmente en entornos de niebla (fog computing).

En este contexto, la creciente fragmentación de plataformas edge exige soluciones altamente flexibles y escalables, lo cual ha impulsado el desarrollo de técnicas de **virtualización ligera**. Estas técnicas permiten que múltiples aplicaciones compartan eficientemente el mismo hardware en el borde, sin comprometer el rendimiento ni la seguridad del sistema.

La virtualización ligera, por ejemplo mediante contenedores, se convierte así en un pilar esencial de ECaaS, habilitando:

- Despliegue dinámico de microservicios en nodos edge.
- Optimización de recursos locales.
- Movilidad de cargas de trabajo entre el borde y la nube.
- Aislamiento de procesos en escenarios multi-tenant.

La **virtualización ligera (lightweight virtualization)** ha madurado lo suficiente como para abordar varios de los desafíos emergentes en entornos edge, como el aumento de la complejidad del software ante nuevas exigencias del mercado. Particularmente, los sistemas embebidos se benefician de la virtualización por su capacidad de manejar entornos heterogéneos y múltiples sistemas en competencia, manteniendo transparencia hacia las aplicaciones, lo que elimina la necesidad de modificar su código al migrar entre entornos de ejecución [12].

En el marco de la computación en el borde (edge) y la niebla (fog computing), las capacidades de elasticidad ofrecidas por la virtualización permiten agregar o retirar funciones dinámicamente en función de la demanda. Además, la posibilidad de migrar máquinas virtuales (VMs) entre nodos edge sobre la red introduce una gran flexibilidad en la gestión de la infraestructura.

Otro aporte clave es la seguridad, ya que la virtualización permite separar el entorno base (supervisor o hipervisor) del espacio de usuario. Esto impide que el código que se ejecuta en user space acceda a recursos críticos del sistema.

En los últimos años, estas técnicas han evolucionado hacia entornos embebidos, donde inicialmente se utilizaban hipervisores convencionales adaptados desde entornos de servidor. Con los avances tecnológicos en semiconductores y la reducción de costos, han surgido hipervisores ligeros específicos para sistemas embebidos, capaces de ser implementados desde cero con soporte directo en hardware [13].

2.4. Fundamentos de *machine learning* y *deep learning*

El *machine learning* (ML) puede entenderse como una técnica para que los computadores predigan o tomen decisiones a partir de datos pasados, sin que el programador tenga que codificar explícitamente todas las reglas del sistema [14]. Frente al enfoque tradicional, donde el ingeniero diseña un algoritmo determinista, en ML se construye un modelo a partir de un conjunto de datos etiquetados; dicho modelo se entrena ajustando sus parámetros internos para minimizar el error entre predicciones y observaciones reales [14].

En el ámbito del *deep learning*, los modelos se basan en redes de neuronas artificiales organizadas en capas. Cada neurona aplica una transformación lineal seguida de una función de activación a sus entradas, produciendo una salida que se propaga hacia capas posteriores [14]. Los parámetros libres del modelo son los pesos y sesgos de esas conexiones; su número total determina la complejidad y el tamaño en memoria del modelo [14].

Durante el entrenamiento, las predicciones del modelo se comparan con las etiquetas reales mediante una función de pérdida; el algoritmo de optimización actualiza los parámetros para reducir dicha pérdida. El rendimiento se analiza a lo largo de las épocas mediante métricas como la pérdida y la exactitud, verificando el fenómeno de convergencia del modelo [14].

Los modelos de *deep learning* aceptan y generan datos en forma de tensores, es decir, arreglos de una o más dimensiones (vectores, matrices, etc.), que constituyen la representación fundamental de la información dentro de estos sistemas [14].

El *framework* TensorFlow es una biblioteca de código abierto para construir, entrenar, evaluar y desplegar modelos de ML, desarrollada originalmente por Google y hoy mantenida por una amplia comunidad [14]. Aunque TensorFlow es apropiado para entrenamiento y despliegue en servidores o dispositivos con recursos relativamente amplios, su intérprete es demasiado pesado para microcontroladores. Por ello, el flujo de trabajo hacia Tiny Machine Learning (TinyML) se basa en TensorFlow Lite (TFLite) y, de manera específica, en TensorFlow Lite for Microcontrollers (TFLM) [14].

Este conjunto de herramientas permite pasar desde un modelo entrenado en entornos de alto rendimiento (PC, GPU, nube) a una implementación eficiente en microcontroladores y dispositivos de ultra-bajo consumo, lo que constituye la base tecnológica de TinyML tal como se presenta en el libro [14].

2.5. Susceptibilidad de incendios forestales

En este trabajo se distingue claramente entre *susceptibilidad* y *detección* de incendios forestales. La susceptibilidad alude a la probabilidad espacial de que se produzca una ignición bajo ciertas condiciones de combustible, clima, topografía y presión antrópica, aun cuando no exista fuego visible, mientras que la detección se centra en identificar focos ya activos mediante sensores ópticos, térmicos o cámaras en tierra o satélite. El foco de esta tesina está en la primera categoría: estimar la propensión del territorio a la ignición para apoyar la planificación y la generación de alertas tempranas condicionadas por el contexto.

La *susceptibilidad* de incendios forestales se concibe teóricamente como la estimación probabilística de la ocurrencia de incendios en una región dada [3], es decir, la propensión intrínseca del territorio a que se produzca una ignición bajo determinadas condiciones ambientales y antrópicas, y no el fuego observado en sí. Sobre esta base, un *modelo de susceptibilidad* es un modelo predictivo espacial que, para cada unidad de análisis (píxel), estima la probabilidad de pertenecer a la clase “fuego” o “no fuego” a partir de un conjunto de variables explicativas, mientras que el *mapa de susceptibilidad* corresponde a la representación cartográfica continua de esas probabilidades, posteriormente reclasificadas en categorías de riesgo tales como muy baja, baja, moderada, alta y muy alta [3].

La formulación del modelo se apoya en la integración de factores de diversa naturaleza que condicionan la ignición y propagación del fuego. En términos generales, se consideran cuatro grandes grupos de variables: topográficas (elevación, pendiente, orientación), climáticas o meteorológicas (temperatura media, precipitación media, velocidad del viento, rugosidad de la superficie, entre otras), de vegetación (Índice de Vegetación de Diferencia Normalizada (NDVI)) y asociadas a la actividad humana y la accesibilidad (distancia a carreteras y a ríos, empleadas como indicadores indirectos de presencia e infraestructura humana) [3]. Desde la teoría del modelo, la selección de estos factores se realiza mediante análisis de multicolinealidad, empleando el factor de inflación de la varianza (VIF) y la tolerancia (TOL), para descartar variables redundantes altamente correlacionadas, y a través del *Information Gain Ratio (IGR)* para identificar la contribución informativa efectiva de cada variable, conservando únicamente aquellas con mérito promedio positivo en la predicción de incendios [3].

En este contexto, las redes neuronales convolucionales (CNN) se emplean como modelos de aprendizaje profundo capaces de capturar relaciones no lineales complejas entre los factores condicionantes y la ocurrencia de incendios, aprovechando la dependencia espacial (“las cosas cercanas están más relacionadas que las lejanas”). Mediante sistemas de información geográfica se construyen conjuntos ráster de variables (*Variable Raster Datasets*, VRD), que combinan en un solo cubo multibanda todos los factores, y conjuntos ráster de ignición (*Ignition Raster Datasets*, IRD), en los que los píxeles situados dentro de un buffer alrededor de eventos históricos se etiquetan como fuego (1) y el resto como no fuego (0), lo que permite abordar el desbalance de clases y representar zonas propensas alrededor de cada ignición [3]. A nivel conceptual, la CNN aprende jerárquicamente patrones espaciales en estos VRD/IRD y produce, para cada píxel o parche, una probabilidad de ignición que se interpreta como susceptibilidad relativa.

Es importante subrayar que estos modelos de susceptibilidad no predicen eventos individuales ni sustituyen a los modelos de propagación: proporcionan un mapa de probabilidad condicionada por el

histórico de incendios y por las variables explicativas disponibles, sujeto además a la no estacionariedad climática. En esta tesina, dicho marco se toma como referencia teórica para trasladar la inferencia de susceptibilidad desde centros de datos en tierra hacia plataformas de *edge computing* a bordo de microsátélites, donde se operará sobre bloques espaciales discretizados (tiles) e índices espectrales derivados de la imagen satelital.

3. Estado del arte

Ante la ausencia de aplicaciones consolidadas que calculen de forma nativa mapas de susceptibilidad a incendios forestales directamente a bordo de plataformas satelitales, el presente estado del arte se organiza en torno a líneas tecnológicas complementarias. En primer lugar, se revisan los modelos de susceptibilidad en tierra basados en aprendizaje automático y profundo, con énfasis en arquitecturas convolucionales contextuales que operan sobre parches ráster multivariados para estimar la probabilidad de ignición a partir de factores físicos y antrópicos, junto con clasificadores clásicos como random forests, máquinas de vectores de soporte, perceptrones multicapa y regresión logística con kernel [3]. En segundo lugar, se abordan las aplicaciones de detección y análisis de fuego en imágenes, tanto desde sensores remotos como desde cámaras terrestres, donde predominan las tareas de clasificación y segmentación de imágenes de alta resolución ejecutadas en plataformas con capacidades de cómputo muy superiores a las de un CubeSat.

En este marco, buena parte de las soluciones actuales se sitúan en la categoría de sistemas de cómputo terrestre que procesan datos satelitales y otras capas geoespaciales para generar mapas de susceptibilidad. Siguiendo enfoques como el de Zhang et al. [3], los factores de incendio se preprocesan como conjuntos ráster multibanda (VRD) y se combinan con inventarios históricos de igniciones (IRD) para entrenar una CNN en infraestructuras de alto desempeño, típicamente con GPU y bibliotecas de deep learning como TensorFlow y Keras. Tras la optimización y validación mediante métricas como exactitud global y área bajo la curva ROC, el modelo se aplica sobre nuevos periodos o escenas para producir en tierra mapas de probabilidad de incendio, que posteriormente se integran en sistemas de apoyo a la decisión, plataformas de monitoreo o servicios operativos basados en teledetección [3]. Este tipo de soluciones actúa como un puente entre la capacidad observacional de los satélites y la inteligencia predictiva avanzada, todavía alojada mayoritariamente en centros de datos terrestres, pero con un potencial claro de migración parcial o total hacia arquitecturas embarcadas en el futuro [3].

En la línea de *edge computing* en órbita, plataformas como SpaceCloud y Nebula, junto con marcos de integración espacio-tierra tipo SAGIN, demuestran que desplazar el procesamiento al segmento espacial permite descargar productos orientados a información (detecciones, vectores, polígonos) en lugar de imágenes crudas, priorizar fragmentos de eventos y aproximar el tiempo real operativo requerido para la respuesta a desastres. En la misma dirección, experiencias como WorldFloods y arquitecturas como EO-ALERT, apoyadas en enlaces ópticos tipo Space Data Highway, evidencian reducciones drásticas de latencia cuando el satélite entrega directamente productos accionables [15]. Sin embargo, cuando el objetivo es pasar de la mera detección a la predicción incidente específica que apoye el despacho táctico, el cuello de botella trasciende lo computacional: entran en juego las limitaciones de revisita, la sensibilidad a condiciones atmosféricas y la necesidad de una cadena operacional de fusión multimodal (SAR, meteorología, óptico/IR) robusta y orquestada extremo a extremo, que no siempre está disponible con tiempos garantizados.

En la teledetección satelital tradicional, sensores ópticos e infrarrojos como MODIS, VIIRS, Sentinel y Landsat permiten detectar puntos calientes y caracterizar áreas quemadas mediante índices como el Índice de Quemado Normalizado (NBR) y NDVI, aportando cobertura regional y largas series históricas. No obstante, su baja frecuencia de revisita (especialmente en Sentinel-2/Landsat), la resolución insuficiente para focos pequeños y la degradación bajo nubosidad o humo obligan a un preprocesamiento intensivo y a la combinación con otros sensores, lo que incrementa la latencia y el riesgo de falsos negativos, alejando estos productos de la ventana táctica inmediata [16,17]. Incluso propuestas de nuevas constelaciones dedicadas, como prototipos tipo FireSat, orientadas a mejorar revisita y resolución térmica, siguen enfrentando el desafío de asegurar un “pipeline” embarcado que transforme la observación en una señal de susceptibilidad accionable y oportuna para el despliegue en terreno.

En el borde terrestre, redes de cámaras y torres como “Fire Foresight” (basada en cámaras Axis y analítica con IA), “Nature Vision/Cellnex y BSeed WATCH” muestran que es posible detectar humo o llamas con minutos de ventaja respecto de observadores humanos, reduciendo latencias gracias a la inferencia local en el dispositivo. Paralelamente, redes IoT de sensores de bajo consumo miden temperatura, humedad del combustible, gases y viento, recurriendo en zonas sin infraestructura a enlaces de baja tasa donde el preprocesamiento local permite transmitir metadatos o alertas en lugar de video [18,19,20]. Pese a estos avances, la cobertura efectiva depende críticamente de la densidad de despliegue, la calidad de la conectividad, el mantenimiento en zonas remotas y la interoperabilidad entre sistemas; por ello, incluso aplicando *edge computing* en redes terrestres, la predicción oportuna y confiable antes de la aparición de llama visible no escala fácilmente hacia las áreas donde más se requiere.

Desde el punto de vista algorítmico, la detección basada en visión por computador en cámaras RGB/IR ha evolucionado desde enfoques de textura y color (LBP, HSV) hacia redes convolucionales profundas como YOLO, Faster R-CNN y MobileNet, incluyendo variantes ligeras orientadas a *edge computing* que equilibran precisión y consumo energético. Sin embargo, su desempeño es altamente sensible a condiciones de iluminación, presencia de humo, reflejos y contexto de la escena, y en general se mantiene como un enfoque reactivo centrado en la detección de humo o llamas, más que en la estimación de susceptibilidad previa de ignición [16]. En el ámbito satelital, el uso de ensambles de redes profundas convolucionales ha alcanzado resultados competitivos en la detección de hotspots y la segmentación multiespectral [16,21], pero persisten desafíos asociados al etiquetado en presencia de fuego, la proliferación de falsos positivos y la transferencia entre biomas [22], lo que dificulta convertir estas salidas en señales predictivas estables para decisiones tácticas, al requerirse flujos de procesamiento más integrados y robustos.

Para robustecer la evidencia mediante fusión multisensor y orquestación, marcos como “SMOKE” y sistemas de apoyo a la decisión como “S2IGI y SAD” integran detecciones locales, hotspots satelitales y variables meteorológicas con el fin de reducir falsos positivos y enriquecer el contexto operativo. No obstante, en operaciones reales persisten heterogeneidades en protocolos, latencias y estructuras de datos que exigen mecanismos de orquestación muy sólidos; la falta de integración fluida termina introduciendo demoras que degradan el valor táctico de la información [23,24,18].

En el ámbito de los modelos de susceptibilidad, índices meteorológicos como el Índice Meteorológico de Peligro de Incendios (FWI), desarrollado en Canadá, que resume en un solo valor cómo las condiciones del tiempo favorecen la ignición y la propagación del fuego [25], representan de forma agregada la humedad del combustible y el tipo de vegetación, pero tienden a sobrestimar el peligro en regiones limitadas por combustible y a dificultar la extrapolación entre biomas. Por su parte, los modelos de susceptibilidad basados en aprendizaje automático generan mapas de probabilidad útiles para la planificación y la zonificación, aunque no predicen eventos puntuales y sufren problemas de desbalance de clases y variabilidad de desempeño, dejando explícita la brecha entre indicadores de riesgo diario/semanal y la susceptibilidad puntual de ignición. Modelos de propagación como “FARSITE y Cell2Fire,” junto con propuestas recientes de predicción de propagación basadas en datos multimodales y redes neuronales, aportan valor para escenarios tácticos, pero dependen de insumos actualizados y de una cadena operacional integrada para que sus resultados lleguen “a tiempo” a los equipos en terreno.

En síntesis, los desarrollos existentes muestran fortalezas parciales pero también limitaciones estructurales: SpaceCloud, Nebula, WorldFloods y EO-ALERT evidencian que el procesamiento a bordo puede entregar productos accionables casi en tiempo real, pero no resuelven por sí solos los problemas de revisita, condiciones atmosféricas y fusión extremo a extremo requeridos para una susceptibilidad táctica robusta; MODIS, VIIRS, Sentinel y Landsat aportan cobertura amplia e historial, pero la revisita y el preprocesado introducen latencias incompatibles con la asignación inmediata de recursos; Fire Foresight, Nature Vision/Cellnex y las redes IoT detectan con rapidez allí donde existe infraestructura, pero su escalamiento enfrenta fricciones de costo, mantenimiento y conectividad en zonas remotas; SMOKE, S2IGI y SAD avanzan en integración y soporte a la decisión, aunque la fragmentación de datos y los desafíos de orquestación siguen generando demoras operacionales; finalmente, los modelos de susceptibilidad y los índices de peligro como FWI son valiosos para planificar, pero no entregan aún señales puntuales, confiables y oportunas que permitan decidir, en el corto plazo, dónde repositionar recursos.

A la luz de este panorama, el uso de *edge computing* para la susceptibilidad de incendios forestales emerge como un aporte significativo: al acercar la inferencia de modelos de inteligencia artificial a la propia plataforma de observación, es posible transformar constelaciones ligeras como los CubeSat en nodos de predicción embarcada capaces de generar alertas compactas y de baja latencia. Esta adaptación de la tecnología hacia sistemas más livianos, eficientes y rápidos no solo optimiza el uso de ancho de banda y reduce la dependencia de infraestructuras terrestres densas, sino que también contribuye de manera directa a una gestión más segura del territorio y de las comunidades, habilitando decisiones tempranas que favorecen una vida más protegida y la economía frente al creciente riesgo de incendios en la Tierra.

4. Desarrollo de la solución

4.1. OE1: Definir y simular el concepto de operaciones (CONOPS) y los parámetros orbitales de la misión NGEN-MAWIDA, evaluando sobre el área de interés (AOI) la cobertura, tiempos de revisita y ventanas de visibilidad, para establecer las restricciones temporales de captura, procesamiento y enlace.

4.1.1 Concepto de operaciones (CONOPS)

La **misión** denominada con nombre “NGEN-MAWIDA”, lo cual refiere en la mitología Mapuche a “espíritus protectores del bosque nativo”, y está definida como una misión de Observación de la Tierra para predecir la generación de incendios forestales. En la Figura 2, se visualiza el CONOPS de la misión, donde un satélite dentro del trayecto de órbita que recorre sobre el territorio, captura una escena, procesa a bordo las imágenes capturadas utilizando IA y descarga o transmite selectivamente una alerta ante un alto riesgo o susceptibilidad de ignición de foco de incendio. Todo lo cual transcurre en el tiempo de duración de la trayectoria o pasada del satélite por el área de interés y zona de cobertura de la estación terrena.




Figura 2. Diagrama CONOPS: concepto de operaciones del sistema, mostrando la captura de información sobre la zona de interés y descarga de alertas al segmento terrestre.

La órbita optimizada para este tipo de misiones se encuentra clasificada dentro de la órbita terrestre baja, en específico a 550 Km y siendo la misión de referencia los parámetros definidos para el satélite chileno “FASat C” [26]. En la Figura 3, se muestran a la izquierda los elementos del plano orbital para esta misión la cual se caracteriza por contener 6 elementos orbitales [27], los cuales están optimizados para la revisita del satélite sobre territorio Chileno.

En esta órbita, como se ve en Tabla 1 el **semieje mayor** $a = 6,910$ km define el tamaño medio de la elipse y está ligado directamente al **período orbital** $T = 1,59$ h, es decir, al tiempo que tarda




Figura 3. Elementos orbitales para la misión NGEN MAWIDA. Modelado en Orbit Architect [28].

el satélite en completar una vuelta alrededor de la Tierra. La **excentricidad** define que tan elíptica será la órbita; en este caso, es muy pequeña, $e = 0,000135$, lo cual significa que la trayectoria es prácticamente circular. La **inclinación** $i = 97,8324^\circ$ indica que se trata de una órbita casi polar, lo cual permite que cubra la mayoría de las latitudes del planeta. El **nodo ascendente** $\Omega = 59,1059^\circ$ fija la orientación del plano orbital respecto al eje de referencia inercial (Vernal Equinox), mientras que el **argumento del perigeo** $\omega = 78,3498^\circ$ indica la ubicación del perigeo, el punto más cercano de la órbita a la tierra, dentro de ese plano. La **anomalía verdadera** $\nu = 248,50^\circ$ señala la posición concreta del satélite sobre su órbita en el instante considerado. De estos parámetros se derivan la **altura de perigeo** $h_p \approx 531$ km y la **altura de apogeo** $h_a \approx 533$ km, que muestran que la órbita es casi circular, así como una **velocidad orbital** media de aproximadamente $v = 7,6$ km/s, con la que el satélite se desplaza alrededor de la Tierra.

Tabla 1. Elementos orbitales de la simulación Misión NGEN-MAWIDA.

Símbolo	Parámetro	Valor
a	Semieje mayor	6.910 km
e	Excentricidad	0,000135
i	Inclinación	$97,8324^\circ$
Ω	Ascensión recta del nodo ascendente	$59,1059^\circ$
ω	Argumento del perigeo	$78,3498^\circ$
ν	Anomalía verdadera	$248,50^\circ$
T	Período orbital	1,59 h
h_a	Altura de apogeo	533 km
h_p	Altura de perigeo	531 km
v	Velocidad orbital (media)	7,6 km/s

Como **concepto de operaciones**, el satélite deberá capturar imágenes sobre un Área de Interés (AOI) definida en la zona centro y centro-sur de Chile. Con una latencia extremo a extremo menor a 5 minutos deberá ejecutar el procesamiento a bordo de las imágenes para estimar la susceptibilidad de ignición de incendios forestales, desacoplando temporalmente la captura de la inferencia y de la transmisión de resultados. Asimismo, deberá habilitar la emisión de alertas desde la órbita cuando la probabilidad estimada de inicio de fuego supere un umbral configurable, transmitiendo de inmediato dichas alertas a alguna estación terrena en cobertura (estación liviana o estación principal), incluyendo

como mínimo las coordenadas geográficas del punto, el nivel de confianza y el identificador de escena, en paquetes de tamaño reducido acordes al enlace disponible.

La configuración del satélite de referencia será optimizada para este concepto operacional, considerando las diferentes cargas útiles y subsistemas que contribuyen a la misión definida. De manera preliminar, se define un satélite CubeSat 12U con capacidad para cuatro cargas útiles: un sensor electro-óptico, una carga útil de comunicaciones, una carga útil alternativa para transmitir pequeños paquetes de datos a través de internet, y una carga útil destinada al procesamiento de *edge computing* para la susceptibilidad de incendios forestales. En este mismo sentido, la referencia técnica de la plataforma a utilizar será equivalente a los microsátélites de la empresa GOMESPACE, cuya documentación técnica se puede descargar desde la página web [29].

La información previa con la que se cuenta para evaluar la interacción de la misión espacial respecto a los elementos temporales técnicos de la órbita y cobertura son determinantes para la predicción de focos de incendios forestales. En este sentido, como estudio de factibilidad, algunos aspectos del diseño preliminar serán presentados para el análisis de la misión y su aplicación en AOI definida como las regiones centrales de Chile basado en la información histórica de mayor afectación [17,22,30]. En este sentido, se evaluará la cobertura de la misión de la zona centro y centro sur de Chile, desde la región de Valparaíso hasta la región de Los Lagos, lo que se describe en el polígono que se muestra en la Figura 4 abarcando una distancia lineal de norte a sur de aproximadamente 1.000 km.




Figura 4. Área de Interés de captura de la misión NGEN MAWIDA. Modelado en Google Earth

El diseño de la órbita obedece a la cobertura requerida para la misión, en este sentido, las órbitas heliosíncronas son órbitas polares que permiten que el satélite pase sobre el AOI a la misma hora local cada día. En relación al rango de horas donde el número de incendios aumenta desde media mañana y alcanza su pico entre aproximadamente el mediodía y las primeras horas de la tarde, cuando el ambiente está más cálido y seco [31]. En Chile, las estadísticas históricas de CONAF incluyen la ocurrencia nacional de incendios forestales según rango horario, donde se observa esta misma concentración en las horas de mayor temperatura y menor humedad relativa [32].

Por lo tanto, se ha definido el rango temporal de cobertura entre las 12:00 y 14:00 hora local en Chile. Estos horarios se consideran de *mayor ocurrencia* por las siguientes razones:

- A esa hora se combinan temperaturas máximas, humedad relativa mínima y vientos más activos, lo que seca rápidamente los combustibles finos y aumenta la probabilidad de ignición y propagación [30].
- El contenido de humedad de la vegetación fina responde muy rápido a estos cambios diarios; al mediodía-tarde está en sus valores más bajos, lo que facilita que cualquier chispa inicie un incendio [30].
- Son también las horas de mayor presencia y actividad de personas en el campo y en la interfaz urbano-rural (trabajos agrícolas o forestales, uso recreativo, quemas, tránsitos), aumentando

la probabilidad de igniciones antropológicas, que son la causa dominante en Chile y en muchas regiones del mundo [30,22].

4.1.2 Evaluación de casos de uso: procesamiento en el borde, tiempos de inferencia, cobertura y descarga de alertas

En el contexto del estado del arte en procesamiento a bordo, la misión EO-ALERT y aplicaciones SAR [15,33], constituyen un referente directo para analizar los tiempos de captura, inferencia y descarga de productos de alto nivel. A partir de sus resultados, es posible extraer parámetros temporales que sirven como línea base para validar preliminarmente la propuesta de utilizar microsátélites con capacidades de *edge computing* para la estimación de susceptibilidad de incendios forestales.

El rasgo común de estas iniciativas es que el procesamiento se realiza directamente en el satélite, evitando el envío de datos crudos a tierra. Los tiempos de ejecución dependen de la aplicación y de la arquitectura hardware, pero los órdenes de magnitud reportados son:

- **Escenario de detección de barcos (EO óptico):** utilizando una arquitectura óptica configurable, el procesamiento de una imagen individual que cubre un área de aproximadamente 54 km^2 toma 35 s. En un esquema de multiprocesamiento paralelo, una secuencia de imágenes que cubre del orden de 900 km^2 se procesa en aproximadamente 110 s [15].
- **Escenario meteorológico (*nowcasting*):** para observación meteorológica extrema, el procesamiento de imágenes que cubren casi $7,1 \times 10^6 \text{ km}^2$ se completa en torno a 15 s [15].

Estos valores se han obtenido sobre plataformas ópticas con hardware configurable y son representativos del rendimiento alcanzable cuando se optimiza la cadena de procesamiento para un conjunto de tareas bien definido.

Para evaluar la factibilidad de una misión de vigilancia y procesamiento en tiempo casi real, se considera además el rendimiento de arquitecturas de procesamiento a bordo sobre plataformas ópticas y de Radar de Apertura Sintética (SAR), como en misiones de detección de pesca ilegal o monitoreo de carga [15].

En el dominio óptico, el procesamiento de un bloque de datos crudos que cubre un área aproximada de 54 km^2 ($9 \text{ km} \times 6 \text{ km}$) requiere un tiempo de computación de 35 s en una configuración de placa única [15]. Para coberturas mayores, la implementación de esquemas de multiprocesamiento paralelo permite analizar superficies de hasta 900 km^2 en aproximadamente 110 s y del orden de 1200 km^2 en 150 s, incluyendo los retardos asociados a transferencia interna de datos y gestión de tareas [15].

En el caso de sensores SAR, críticos para la detección bajo cualquier condición meteorológica, las arquitecturas optimizadas de procesamiento a bordo reportan tiempos de latencia total (generación de la imagen más ejecución del algoritmo de detección de barcos) inferiores a 40 s para bloques de aproximadamente 375 km^2 ($12,5 \text{ km} \times 30 \text{ km}$). Mediante el procesamiento secuencial de múltiples bloques, es posible cubrir del orden de 1125 km^2 en menos de 120 s [15,33].

Tras la etapa de determinación de susceptibilidad o detección, el sistema genera *alertas* en forma de metadatos encriptados (posición, movimiento, identificación, nivel de confianza), cuyo volumen de datos es muy inferior al de la imagen original. Esto permite emplear enlaces de retransmisión global de ancho de banda limitado pero alta disponibilidad.

Para la transmisión de estas alertas en escenarios globales, EO-ALERT emplea sistemas de retransmisión de datos intersatelitales (por ejemplo, el servicio **iDRS** a través de la red Inmarsat). Las métricas experimentales indican una velocidad de transferencia típica de 250 kbit/s [15]. A esta tasa, el sistema es capaz de transmitir un paquete de **100 alertas en 37 s** [15]. De estos parámetros se deduce el tamaño promedio por alerta individual:

$$Size_{\text{alerta}} \approx \frac{250 \text{ kbit/s} \times 37 \text{ s}}{100 \text{ alertas}} \approx 92,5 \text{ kbit/alerta} \approx 11,5 \text{ kB/alerta}.$$

Integrando las etapas de procesamiento y transmisión, la latencia extremo a extremo desde la adquisición hasta la llegada de la alerta a tierra se puede modelar como:

$$T_{\text{total}} = T_{\text{procesamiento}} + T_{\text{cifrado}} + T_{\text{transmisión}}.$$

En un escenario nominal tipo EO-ALERT para detección con SAR u óptico [15,33] se tienen, de forma representativa:

- **Procesamiento:** $T_{\text{procesamiento}} < 40$ s por bloque de 375 km^2 .
- **Cifrado/compresión:** tiempo despreciable frente al procesamiento de imagen cuando sólo se cifran metadatos (orden de milisegundos), aun cuando el cifrado de imágenes completas pueda requerir $\sim 100 \text{ ns/pixel} \sim 100 \text{ ns/pixel}$.
- **Transmisión:** $T_{\text{transmisión}} < 1$ s por alerta individual a 250 kbit/s , incluyendo cabeceras de protocolo.

Desde el punto de vista hardware, EO-ALERT implementa estas cadenas de procesamiento sobre una Unidad de Procesado de Datos de la Carga Útil (PDPU) modular basada en el estándar cPCI Serial Space y hasta siete placas periféricas. Todas las tarjetas integran un MPSoC Xilinx Zynq UltraScale+ ZU19EG, que combina un procesador ARM de cuatro núcleos con una FPGA de gran capacidad en el mismo encapsulado, de modo que las etapas más intensivas (generación de imagen óptica y SAR, compresión y cifrado) se aceleran en lógica programable mientras que las CPUs se reservan para control de flujo, coordinación de tareas y gestión de datos. Las placas se interconectan mediante enlaces PCIe Gen3 de alta velocidad (del orden de 1 GB/s), complementados con enlaces Time-Triggered Ethernet a 1 Gbit/s hacia los sensores y el subsistema de comunicaciones, proporcionando la infraestructura necesaria para alcanzar las latencias objetivo de la misión [15].

En consecuencia, la arquitectura tipo EO-ALERT y aplicaciones SAR permite entregar alertas de seguridad con una latencia global típicamente inferior al minuto, valor coherente con los requisitos de aplicaciones de vigilancia crítica [15,33]. Este comportamiento contrasta con los retrasos de 12 h a 48 h característicos de los esquemas tradicionales basados en captura, descarga masiva de imágenes y procesamiento en tierra.

En el contexto de la presente misión, donde la hipótesis operacional establece una ventana efectiva de aproximadamente 150 s para la captura sobre el área de interés y en torno a 434 s de visibilidad con estación terrena, estos valores de referencia demuestran que la cadena captura–procesamiento a bordo–descarga de alertas puede ejecutarse holgadamente dentro de una ventana de 5 min . La Tabla 2 resume los parámetros clave utilizados como objetivos de diseño para el cálculo de la latencia extremo a extremo en el caso de uso de incendios forestales.

Tabla 2. Resumen de parámetros clave para el cálculo de latencia

Parámetro	Valor típico
Tiempo proc. óptico (unitario)	35 s (54 km^2)
Tiempo proc. óptico (paralelo)	110 s (900 km^2)
Tiempo proc. SAR (total)	$< 40 \text{ s}$ (375 km^2)
Velocidad de enlace (relay)	250 kbit/s
Tasa de transferencia de alertas	$100 \text{ alertas} / 37 \text{ s}$
Tamaño est. paquete de alerta	$\sim 11,5 \text{ kB}$
Latencia objetivo global	$< 5 \text{ min}$

4.2. (OE2): Diseñar e implementar, a nivel de modelo, un pipeline de edge computing sobre una plataforma satelital de referencia, y estimar su desempeño en términos de tiempo de inferencia, uso de memoria, consumo de energía y volumen de datos de alertas.

La determinación de la susceptibilidad de incendios forestales en entornos computacionales con recursos limitados, como los que se pueden encontrar en plataformas de borde (edge) o en satélites CubeSat en órbita, es una tarea que requiere diseñar “pipelines” operativos que integren la captura de imágenes, el análisis multispectral y la inferencia a través de modelos *TinyML* debido a las limitaciones técnicas de las plataformas remotas. Esta aproximación, además de facilitar el procesamiento en tiempo real, garantiza una operación de bajo consumo energético y un uso mínimo de la memoria, aspectos críticos en dispositivos embebidos.

4.2.1 Captura del AOI y generación de datos para edge computing satelital

En el contexto de la misión NGEN-MAWIDA, la etapa de captura sobre el AOI se caracteriza por una ventana de acceso de aproximadamente 150 s cada pasada, definida a partir del análisis de revisita del satélite sobre la zona de captura aumentada que cubre el polígono Valparaíso–Los Lagos

($\approx 1,000$ km norte-sur). Durante ese intervalo, el satélite mantiene el AOI dentro del campo de visión (FOV) del sensor electro-óptico gracias a la combinación de la órbita heliosíncrona y la capacidad de apuntamiento del sistema de observación.

Como referencia para el diseño de la carga útil de *edge computing* se adopta una cámara multiespectral de referencia [29]. Este sensor dispone de 4096 píxeles, 12 bits de profundidad radiométrica y 8 bandas espectrales, con una resolución en tierra de 5 m de GSD a 550 km de altitud [29]. Cada imagen elemental (*spot*) cubre un área aproximada de $5,7 \text{ km} \times 5,7 \text{ km}$, es decir, $32,49 \text{ km}^2$ por imagen [29]. Operacionalmente, una escena se define como un conjunto de 5 imágenes consecutivas, por lo que la superficie por escena asciende a alrededor de $162,45 \text{ km}^2$.

La documentación de diseño establece que, en modo de operación continua, el satélite puede adquirir del orden de 1 escena por segundo, lo que implica que el barrido del terreno (considerando la velocidad orbital y el barrido del sensor) permite registrar aproximadamente 3 escenas en 3 s, equivalentes a unos 478 km^2 cubiertos en ese intervalo [29]. Extrapolando este régimen a la ventana de captura de 150 s sobre el AOI, se obtiene una capacidad teórica máxima del orden de:

- 150 escenas por cada pasada ($1 \text{ escena/s} \times 150 \text{ s}$),
- 750 imágenes individuales (5 imágenes por escena),
- 24.000 km^2 de superficie observada en el entorno del AOI.

Esta cifra constituye una cota superior de la superficie potencialmente observable por pasada, asumiendo que la cámara opera de forma continua y que el apuntamiento permite barrer de extremo a extremo la zona de captura. En la práctica, el plan de misión restringirá este máximo en función de prioridades operacionales, limitaciones térmicas y de energía, y de la necesidad de concentrar la adquisición en subregiones del AOI con mayor riesgo de incendio.

Desde la perspectiva del servicio de *edge computing* en microsátélites, esta parametrización de la etapa de captura permite:

- Discretizar el AOI en escenas de 162 km^2 bien definidas geométricamente, alineadas con la huella de la cámara multiespectral.
- Derivar *tiles* de procesamiento, por ejemplo bloques de 54 km^2 , coherentes con el análisis de los casos de uso de procesamiento a bordo, como subunidades dentro de cada escena para alimentar los modelos de IA [29].
- Dimensionar el *pipeline* a bordo asumiendo que, durante una pasada típica, solo se procesará una fracción seleccionada de las escenas capturadas, priorizando aquellas que intersectan el AOI ampliado y presentan condiciones de mayor susceptibilidad a incendios.

En síntesis, la etapa de captura del AOI con cámara multiespectral en un microsátélite proporciona un marco cuantitativo claro sobre cuánta superficie puede ser observada por pasada y cómo se estructura espacialmente esa observación (*spots*, escenas, *tiles*), lo que es clave para el diseño y validación de servicios de *edge computing* orientados a la susceptibilidad de incendios forestales.

Desde el punto de vista de la generación de datos previa a la inferencia, la misión se articula en torno a tres niveles encadenados: definir qué variables se requieren, cómo se obtienen o derivan en el AOI y, finalmente, cómo se estructuran en unidades de muestra adecuadas para los modelos de aprendizaje profundo.

En primer lugar, el satélite debe generar variables derivadas directamente de la imagen multiespectral obtenida por el sensor a bordo con 8 bandas en el rango VNIR y 12 bits de profundidad. A partir de estas bandas se calculan a bordo índices espectrales de interés para riesgo de incendio, en particular NDVI y NBR, ya consolidados como indicadores indirectos de estrés hídrico y estado de la vegetación. Sobre esta misma base se generan productos auxiliares rápidos, como composiciones RGB y máscaras de nubes y sombras, siguiendo un patrón similar al de las soluciones hiperespectrales en agricultura de precisión, pero adaptado a la carga útil multiespectral del CubeSat 12U.

En paralelo, el sistema incorpora capas ambientales y antrópicas que no se obtienen en órbita sino que se preprocesan en Tierra y se cargan al satélite como información de contexto. Estas capas replican el enfoque de los modelos de susceptibilidad, combinando variables topográficas (elevación, pendiente, orientación), de uso y cobertura de suelo, distancia a ríos y variables antrópicas como distancia a caminos, núcleos urbanos e infraestructuras. A ello se suman capas dinámicas que modulan el riesgo

día a día: temperatura, viento, humedad, precipitación, índices de sequía o derivados del FWI, además de índices de vegetación calculados sobre series temporales (NDVI multi-fecha).

Sobre las escenas capturadas se construye la unidad de trabajo para la inferencia a bordo: los *tiles* o bloques de proceso. Cada escena se proyecta geométricamente sobre el AOI mediante una corrección ligera basada en los parámetros de órbita y actitud, y después se corta en *tiles* de área manejable para el hardware de a bordo, por ejemplo bloques de unos 54 km². Dentro de cada *tile*, la información se discretiza aún más en parches espaciales (*patches*) de tamaño fijo en píxeles. La experiencia de los modelos de susceptibilidad con *deep learning* en Tierra señala como tamaño óptimo parches de 25×25 píxeles para combinar factores y etiquetas, mientras que en estudios basados en NDVI y NBR sobre Landsat-8 se han utilizado parches de 50×50. Antes de que estos parches entren al motor de inferencia, los datos pasan por una etapa de preprocesamiento y ensamblado. En términos radiométricos, se aplican correcciones mínimas que aseguren la comparabilidad entre pasadas: normalización de reflectancias y ajustes básicos para compensar variaciones de iluminación. Geométricamente, se realiza un registro aproximado de las imágenes con la malla espacial de las capas externas, utilizando la información de navegación del satélite. A partir de las bandas multispectrales se calculan a bordo los índices NDVI y NBR con sus fórmulas estándar. Luego, sobre la misma malla espacial y la misma fecha, se muestrean las capas exógenas (topografía, distancias a carreteras y ríos, variables meteorológicas y de sequía del día).

En conjunto, todo este flujo pone de manifiesto que la etapa de generación de datos en una misión de *edge computing* satelital no se limita a “tomar fotografías”. Implica capturar escenas dentro de una ventana temporal estricta sobre la zona de captura aumentada, reorganizarlas en *tiles* y *patches* compatibles con las resoluciones espaciales que han demostrado ser eficaces en modelos de susceptibilidad, y enriquecer cada *patch* con índices espectrales y variables ambientales y antrópicas relevantes. Solo cuando ese *pipeline* está completo, la inferencia a bordo opera sobre datos integrados y coherentes espacio-temporalmente en lugar de imágenes brutas, lo que es condición necesaria para que el modelo tenga capacidad real de generalización y aporte valor operativo en la susceptibilidad de incendios.

4.2.2 Pipeline de inferencia para susceptibilidad de ignición de focos de incendio

Tal como se mencionó, la computación en microsátélites cuenta con recursos limitados en relación al espacio disponible para la carga útil computacional, la masa y la energía disponible. En este contexto, las soluciones basadas en *Tiny Machine Learning* constituyen un marco de diseño atractivo: proponen modelos ligeros, cuantizados y con un uso muy eficiente de memoria y cómputo, pensados originalmente para microcontroladores y sistemas de muy bajo consumo[14]. En esta tesina, dicho marco se utiliza principalmente como **referencia metodológica**: se adoptan sus principios de diseño (separar el preprocesado clásico del núcleo de inferencia, redes compactas y cuantizadas, flujo de despliegue vía TensorFlow Lite), pero se implementan sobre plataformas de mayor capacidad que un microcontrolador típico, en particular un Zynq-7000.

El *pipeline* de inferencia para estimar la susceptibilidad de ignición comienza con la adquisición de imágenes multispectrales mediante la cámara MultiScape 100 CIS, con 8 bandas, 12 bits, 4096 píxeles en dirección *cross-track* y 1091 líneas por escena, y un GSD aproximado de 5.225 m. Dado que el Área de Interés (AOI) de la misión NGEN-MAWIDA (franja Valparaíso–Los Lagos) abarca del orden de miles de km², no se procesa como un único tensor, sino que se discretiza en bloques operacionales o *tiles*. Siguiendo como referencia el diseño del demostrador EO-ALERT, donde cada bloque óptico de aproximadamente $9 \times 6 \text{ km} \approx 54 \text{ km}^2$ se procesa a bordo en una única computadora en unos 35 s[15], en esta tesina se adopta un **bloque estándar** de unos 54 km² como unidad de trabajo para el pipeline de inferencia. Este bloque puede formarse con una o varias imágenes consecutivas según la geometría de la pasada, y el AOI completo se cubre como un mosaico de muchos de estos bloques.

La computadora utilizada como *payload gateway* en los microsátélites de referencia[29] se apoya en un SoC de la familia Xilinx Zynq-7000, que combina en un solo dispositivo capacidades de procesamiento flexible y lógica programable. Esta arquitectura permite integrar en una misma plataforma la gestión de las cargas útiles, el enrutamiento eficiente de grandes volúmenes de datos y la ejecución de algoritmos avanzados directamente en órbita. Esta versatilidad permite al satélite preprocesar, filtrar y analizar información antes de su envío a Tierra, lo que convierte a este tipo de SoC en una base adecuada para evaluar, como plataforma preliminar, servicios de *edge computing* a bordo de microsátélites [34,?].

Sobre esta misma plataforma Zynq-7000 con doble Cortex-A9 y 1 GB de DDR3 como computador de carga útil[29], se ejecuta el preprocesado previo a la inferencia con TensorFlow Lite, siguiendo la filosofía del libro *TinyML* de reservar la red neuronal solo para el núcleo de inferencia y dejar el resto del procesamiento a código convencional[14]. Este preprocesado incluye la ingesta de las imágenes desde la electrónica de control de la cámara, el recorte al AOI local y la posible generación de un mosaico para completar el bloque de 54 km², además de correcciones geométricas ligeras y normalización radiométrica. Asimismo, se derivan índices espectrales como NDVI, NBR y otros a partir de las bandas VNIR, y se apilan junto a las bandas originales para formar un tensor tipo imagen 2D×canales adecuado para modelos de visión ligeros [34,35].

En el dominio espacial, cada bloque de 54 km² puede tratarse, por simplicidad de implementación en TFLite, dividiéndolo en una rejilla de ventanas 2D fijas, en parches de 256×256 píxeles, cada uno con todas las bandas e índices como canales. Cada parche se normaliza antes de ser alimentado al modelo[14]. Sobre estos tensores se aplica un modelo tipo TinyML basado en una CNN muy ligera, con convoluciones *depthwise separables* 3×3 y pocos canales de salida, cuantizada a 8 bits para reducir memoria y coste de cómputo sin pérdida severa de precisión [14]. El cuerpo de la red se limita a una o dos capas convolucionales *depthwise separables*, siguiendo el patrón de los ejemplos de visión embebida de *TinyML* [14]. La salida del modelo puede ser un escalar de susceptibilidad para cada parche (por ejemplo, riesgo bajo/medio/alto) o bien un mapa de calor de baja resolución (por ejemplo 32×32 o 64×64) con valores continuos entre 0 y 1 que se reescalan a la malla original del sensor.

El modelo entrenado en Tierra con TensorFlow, se cuantiza y se convierte a un archivo TFLite. En Zynq-7000, este modelo TFLite se ejecuta sobre el sistema operativo embarcado aprovechando las extensiones NEON de los núcleos Cortex-A9[36]. En órbita, la inferencia genera, para cada bloque de 54 km², un mapa de susceptibilidad de ignición que se somete a un postprocesado adicional: reproyección a coordenadas geográficas, umbralización (por ejemplo, marcando como alto riesgo los valores por encima de 0.7) y agrupamiento de píxeles o celdas de alta susceptibilidad en *clusters* que representan posibles *hotspots*, sobre los que se calculan métricas como área, susceptibilidad media y proximidad a infraestructuras o poblaciones[22,37]. La concatenación espacial de los resultados de todos los bloques genera finalmente un mapa de susceptibilidad para el AOI completo.

En cuanto al presupuesto computacional, se puede estimar el límite razonable de FLOPs usando el cálculo implícito en *TinyML*: un microcontrolador típico puede ejecutar en torno a 1 millón de FLOPs en 100 ms, lo que equivale a unos 10 MFLOPs/s[14]. Tomando como referencia el caso EO-ALERT, donde se requiere procesar un bloque óptico de aproximadamente 54 km² en unos 35 s por computador de a bordo [15], se fija como requisito análogo procesar un bloque de 54 km² en un máximo de 35 s. Bajo esta hipótesis, el presupuesto total para el modelo de inferencia sería de aproximadamente 350 MFLOPs por bloque. Considerando el GSD del sensor (5.225 m), un bloque de 54 km² contiene en el orden de 2×10^6 píxeles, lo que implica un presupuesto medio de unos 175 FLOPs por píxel para mantener el tiempo de proceso dentro de esos 35 s en un microcontrolador de referencia. Cualquier arquitectura, tanto basada en parches como que opere sobre el bloque completo reescalado, debería diseñarse de forma que su coste total por inferencia no supere aproximadamente esos 350 MFLOPs, dimensionando cuidadosamente número de canales, capas y tamaño espacial de las características [14].

La situación real a bordo del satélite es, sin embargo, bastante más holgada que la de un microcontrolador típico TinyML. El Zynq-7000 con doble ARM Cortex-A9 MPCore, capaz de operar hasta 800 MHz en la configuración de esta plataforma y hasta 1 GHz en ciertos dispositivos de la familia, con extensiones NEON y unidad de punto flotante por núcleo[36], ofrece una capacidad de cómputo muy superior. Según la hoja de datos de Zynq-7000, cada núcleo Cortex-A9 ofrece extensiones NEON y operaciones de punto flotante simple y doble precisión, con frecuencias máximas de hasta 1 GHz en los dispositivos de clase alta, y la matriz de lógica programable aporta entre 400 y 900 *slices* DSP[36]. A 800 MHz, una estimación gruesa sitúa el rendimiento de cada núcleo en el orden de 1,6 GFLOPs, es decir unos 3,2 GFLOPs agregados para los dos núcleos, muy por encima de los 10 MFLOPs/s tomados como referencia en *TinyML*, incluso sin contar la aceleración adicional de NEON y la lógica programable [14,36]. Esto implica que un modelo de 350 MFLOPs, dimensionado para ser «seguro» en un microcontrolador modesto, podría ejecutarse teóricamente en torno a una décima de segundo en el Zynq-7000 si se aprovechan bien ambos núcleos y la jerarquía de memoria, quedando un margen de dos órdenes de magnitud respecto al requisito de 35 s por bloque.

En la práctica, esta diferencia permite mantener un diseño de modelo estrictamente TinyML maximizando robustez y simplicidad, y aumentando de forma moderada la complejidad de la red (más canales, capa adicional) sin riesgo de violar las restricciones temporales, tomando en consideración que el Zynq-7000 es, en esencia, una plataforma *Linux-capable* mucho más potente que los microcontroladores que constituyen el foco principal del libro de referencia *TinyML*[14]. Además, el mismo *pipeline* de inferencia —basado en modelos compactos y cuantizados y en el procesado por bloques de 54 km²— es directamente trasladable a otras placas de mayor capacidad con procesadores multinúcleo y aceleradores dedicados (GPU, VPU o NPU), manteniendo latencias de inferencia muy por debajo de las ventanas operativas típicas en aplicaciones de observación de la Tierra y detección temprana de incendios[35].

4.2.3 Estimación previa del consumo eléctrico de la operación

La plataforma de referencia se basa en un microsatélite CubeSat 12U operando en órbita polar heliosíncrona a 550 km. Esta integra un bus modular con subsistemas clásicos de potencia, estructura, ADCS/AOCS, comunicaciones, control y manejo de datos, control térmico y cargas útiles, interconectados mediante buses estandarizados para este tipo de desarrollos I2C y CAN sobre CubeSat Space Protocol, lo que habilita una arquitectura distribuida y escalable. La misión incorpora una carga útil electro-óptica multiespectral, soportada por un sistema eléctrico que entrega ≥ 90 W al inicio de vida y 172 Wh de almacenamiento en baterías, y por un segmento de comunicaciones multi-banda (UHF/S/X) que asegura tanto el enlace de telemetría y telecomando (TT&C) como la descarga masiva de datos científicos, constituyendo una plataforma adecuada para integrar y validar servicios de *edge computing*.

En el Anexo B se realiza una estimación previa del presupuesto de potencia disponible para la carga útil de *edge computing* durante la operación susceptible de incendios forestales. A partir del análisis temporal de la pasada del satélite sobre la cobertura nacional, se identifica que la ventana efectiva de procesamiento a bordo para la carga útil se restringe al intervalo en que ya se han generado imágenes (desde T_2 hasta T_4), con una duración aproximada de 292 s.

Sobre la base del modo de operación denominado “Imaging” de la plataforma, el cual es la operación del sensor electro-óptico, el consumo de la plataforma se sitúa en torno a 37,11 W, incluyendo el AOCS y el enlace de telecomando en banda S en recepción continua. Al añadir el transceptor UHF (4 W), el consumo total del modo “Imaging-On + UH” se eleva a aproximadamente 41 W. Considerando una generación solar efectiva de 64,8 W en peor caso (factor de actitud 0,8 y eficiencia del regulador del 90 %) y una capacidad total de baterías de 158,4 Wh, se fija como criterio de diseño mantener el estado de carga (SOC) por sobre el 80 %, lo que limita la energía máxima consumible por órbita a unas 95 Wh y la potencia media máxima de operación a cerca de 60 W.

Comparando estos límites con el consumo del modo “Imaging-On y UHF”, se obtiene un margen de potencia media disponible del orden de 19 W. Asumiendo que la carga de *edge computing* opera de forma simultánea a dicho modo durante una ventana de aproximadamente 5 minutos por órbita, la energía asociada a esta carga adicional es de alrededor de 1,6 Wh. En consecuencia, el análisis establece que la potencia máxima disponible para la carga útil de *edge computing* es de 19 W, con un límite de energía consumible de aproximadamente 1,6 Wh por órbita en la ventana de procesamiento dedicada.

4.3. OE3: Integrar los resultados orbitales y de cómputo para verificar la factibilidad operacional del servicio ECaaS, comprobando que la cadena captura, procesamiento a bordo y transmisión de alertas cumple la latencia extremo a extremo <5 minutos y se mantiene dentro del presupuesto de potencia de un CubeSat 12U.

4.3.1 Simulación de la dinámica de vuelo

Para su análisis y validación de la misión se generó una simulación de la misión en el software de libre uso “General Mission Analysis Tool (GMAT)”, este permite analizar la misión espacial, órbita, revisita y trayectoria del satélite en relación con la superficie terrestre “grountrack”. Asimismo, genera un análisis respecto del tiempo de conexión con estaciones terrenas satelitales y lo que nos permitirá evaluar la factibilidad de la misión respecto de la cobertura del AOI. Para generar el análisis se han configurado los parámetros de la órbita del satélite de acuerdo a lo definido para el diseño de la misión en la Tabla 1, asimismo, se utilizó como fecha de referencia para inicio de la simulación el “16 Jan 2025 00:00:00.000”,

la configuración de una estación terrena satelital “Groundstation1” en las coordenadas (lat -36.87, lon -72.60), correspondiendo a un punto central ubicado en la región del Bio-Bio. De esta manera, en la Figura 5 se muestra la proyección de la trayectoria del satélite en la superficie terrestre “groundtrack”, la posición de la estación terrena “GroundStation1” y la posición del satélite “NGEN MAWIDA”. Con




Figura 5. Misión espacial y proyección de la Trayectoria satelital en la superficie terrestre “groundtrack”

esta simulación se puede obtener mediante la configuración del comando “ContactLocator1” el tiempo de conexión entre el satélite en órbita y la estación terrena para las fechas desde el 16 al 19 de enero 2025. La información en la Tabla 5 del anexo B, muestra 14 ventanas de visibilidad del satélite con la estación terrena, esto se visualiza en las columnas referenciando el tiempo de inicio, término y duración de la conexión o visibilidad.

Consecuente con el AOI, el satélite deberá ser capaz de cubrir y tomar imágenes de esta en la órbita definida para la misión a 550 km de altura. Para este análisis, se utilizará el comando “ContactLocator2” mediante el cual se evalúa la superposición de las órbitas con el AOI.

En este sentido, existe un ángulo de apuntamiento del elemento sensor electro-optico con el cual capturará escenas desde el espacio. De acuerdo con lo anterior, el ángulo máximo del sensor para este tipo de misiones se definirá como 40° . Este ángulo de apuntamiento, debido a la altura del satélite, genera una distancia mayor de alcance y desplazamiento lateral del satélite, proyectando una zona de acceso a las órbitas al AOI más amplia en superficie. De esta manera, si la órbita del satélite se aproxima por el lado este del polígono existirá una distancia máxima de desplazamiento lateral del satélite el que se obtiene del cálculo trigonométrico del triángulo rectángulo que se muestra en la Figura 6. Este cálculo actualiza y genera un área de acceso de las órbitas mayor que el polígono que define el AOI y generando una nueva superficie dentro de la cual se debe proyectar el “groundtrack” del satélite para una captura óptima.

De este modo, el área de superposición de las órbitas con la zona de captura aumentada se encuentra graficada en la Figura 7.

Por lo tanto, así como para el acceso del satélite a la estación terrena, también existe un tiempo de acceso y revisita del satélite a la zona de captura del AOI delineada en color verde en la Figura 7. Este análisis se lleva a cabo por medio de superponer las órbitas del satélite con el área del polígono definido. En este sentido se aplica el comando “ContactLocator2” en el software GMAT ante lo cual se obtienen los resultados de la Tabla 7 del anexo B.

Finalmente, del análisis temporal desde la Tabla 5 y 7 se obtienen los parámetros de tiempo y las res-




Figura 6. Desplazamiento lateral de la captura de

tricciones a las cuales se deberá acotar el diseño de la misión. De los resultados, se obtiene que la observación del satélite se divide entre diurnas y nocturnas, por lo tanto la captura se optimiza utilizando un sensor capaz de detectar puntos de calor e imágenes en rangos espectrales infrarrojos y visibles. Asimismo, la captura de las imágenes se deberá generar dentro de la ventana de tiempo calculada la cual se encuentra entre los rangos en torno a los **150 s**. Por otra parte, el procesamiento de *edge computing* y la transmisión de las alertas requieren de la cobertura del satélite con la estación terrena, para ello los rangos de acceso o visibilidad, solo tomando en cuenta aquellos mayores a 150 s, en promedio se encuentran en **434 s**.




Figura 7. Zona de captura ampliada del AOI

4.3.2 Validación de la capacidad de inferencia a bordo

Esta sección valida cuantitativamente que la plataforma de cómputo empleada en el modelo de servicios **ECaaS** dispone de capacidad computacional para ejecutar, en órbita, la inferencia necesaria para estimar de forma predictiva la susceptibilidad de focos de incendios forestales en el AOI definido, cumpliendo las restricciones de ventana temporal y presupuesto energético de la misión NGEN-MAWIDA.

La misión se basa en una cámara multispectral tipo MultiScape100 CIS, integrada en la familia xScape100, con 4096 píxeles en dirección cross-track, un total de 8 bandas en el VNIR (1 pancromática y 7 multiespectrales) y 12 bits de profundidad radiométrica [38]. A una altitud de referencia de 550 km, a partir de la especificación de 4,75 m GSD y 19,4 km de *swath* a 500 km, se obtiene una GSD 5,2 m y un ancho de barrido 21,3 km [38]. En este trabajo se define una imagen elemental como un recorte de aproximadamente 5,7 km × 5,7 km (1090 × 1090 píxeles), que cubre 32,5 km², y un bloque operacional de AOI de 54 km² como un recorte de 9 km × 6 km (1720 × 1150 píxeles, 2 × 10⁶ píxeles), lo que con 8 bandas a 12 bits supone un volumen de entrada de 24 MB por bloque.

El análisis orbital para la misión NGEN-MAWIDA establece:

- Una ventana de captura sobre el AOI de 150 s por pasada, durante la cual el satélite mantiene el AOI dentro del campo de visión gracias a la combinación de órbita heliosíncrona y capacidad de apuntamiento.
- Una ventana media de 434 s para procesamiento y descarga de información, que permite solapar captura, inferencia y transmisión de alertas según el CONOPS.

Adicionalmente, estudios de referencia en procesamiento a bordo fijan como requisito de diseño que un bloque óptico de 54 km² pueda procesarse en torno a 35 s en arquitecturas de placa única, cifra que se adopta como límite superior conservador para esta tesina.

Suponiendo una velocidad sobre el suelo de:

$$v_{\text{suelo}} = 7,5 \text{ km/s}$$

el tiempo necesario para adquirir un bloque en dirección along-track (9 km) es:

$$t_{\text{capt,bloque}} = \frac{9 \text{ km}}{7,5 \text{ km/s}} = 1,2 \text{ s}$$

Con una ventana de captura sobre el AOI de 150 s, el número máximo teórico de bloques que puede adquirir la cámara en una pasada es:

$$N_{\text{bloques,captura}} = \frac{150 \text{ s}}{1,2 \text{ s/bloque}} = 125 \text{ bloques}$$

Es decir, en el escenario más exigente, la cámara podría generar hasta 125 bloques de 54 km² por pasada sobre el AOI.

4.3.3 Presupuesto de cómputo del modelo TinyML por bloque

En el diseño del pipeline TinyML para susceptibilidad se adopta como presupuesto máximo por bloque de 54 km² un coste de 350 MFLOPs por inferencia. Este valor proviene de:

- La regla empírica TinyML: un microcontrolador típico ejecuta 1 MFLOP en 100 ms (10 MFLOPs/s).
- El requisito de procesar un bloque de 54 km² en ≤ 35 s, que fija un presupuesto de 350 MFLOPs por bloque en un microcontrolador de referencia.

Dado el GSD del sensor, cada bloque incorpora 2×10^6 píxeles, lo que se traduce en un presupuesto medio de 175 FLOPs por píxel para mantener el tiempo de proceso por debajo de 35 s en un dispositivo TinyML convencional. El pipeline TinyML para susceptibilidad de incendios se dimensiona con un coste máximo de:

$$O_{\text{bloque}} = 0,35 \text{ GFLOPs/bloque} = 3,5 \times 10^8 \text{ operaciones}$$

para cada bloque de 54 km². Para los 125 bloques capturables en una pasada:

$$O_{\text{pasada}} = N_{\text{bloques,captura}} \cdot O_{\text{bloque}} = 125 \times 0,35 \text{ GFLOPs} = 43,75 \text{ GFLOPs}$$

En la configuración de referencia propuesta, un Zynq-7000 que opera a 800 MHz; cada núcleo Cortex-A9, lógica programable (FPGA) y unidad de punto flotante, con un rendimiento estimado de 1,6 GFLOPs por núcleo, es decir, 3,2 GFLOPs efectivos agregados para los dos núcleos. Con esta cifra:

El tiempo necesario para procesar los 43,8 GFLOPs de una pasada es:

$$t_{\text{proc,CPU}} = \frac{O_{\text{pasada}}}{P_{\text{CPU}}} = \frac{43,8 \text{ GFLOPs}}{3,2 \text{ GFLOPS}} = 13,7 \text{ s}$$

En términos energéticos, tomando 7 W como consumo bajo carga:

$$E_{\text{pasada}} = 7 \text{ W} \times 13,7 \text{ s} = 96 \text{ J} = 0,027 \text{ Wh}$$

Distribuido en la ventana de 434 s disponible para procesamiento y enlace, la potencia media asociada exclusivamente a la inferencia es:

$$P_{\text{med,inferencia}} = \frac{96 \text{ J}}{434 \text{ s}} = 0,22 \text{ W}$$

por debajo del margen de 19 W reservado para el servicio de *edge computing*.

En cuanto a memoria y E/S, la DDR3L de 1 GB con bus de 32 bits a 533 MHz proporciona un ancho de banda pico de:

$$BW_{\text{pico}} \approx 32 \text{ bits} \times 1066 \text{ MT/s} \approx 4,26 \text{ GB/s}$$

Considerando una eficiencia real de 60 %, se obtiene un BW efectivo de 2,5 GB/s. Mover los 24 MB de datos crudos de un bloque de 54 km² desde DDR a CPU/PL con buena reutilización de caché requiere del orden de:

$$t_{\text{mem}} \sim \frac{24 \text{ MB}}{2,5 \text{ GB/s}} \approx 0,01 \text{ s}$$

Este valor es un orden de magnitud menor que el tiempo de cómputo en CPU, por lo que la inferencia está limitada por cómputo y no por ancho de banda de memoria.

4.3.4 Latencia extremo a extremo: captura, inferencia y descarga de alertas

El modelo de servicios ECaaS fija como restricción principal que la **latencia extremo a extremo** (captura de escena sobre el AOI, inferencia y transmisión de alertas a Tierra) sea inferior a 5 minutos, en coherencia con la hipótesis operacional de la misión NGEN-MAWIDA. El análisis orbital realizado con GMAT muestra que, en las pasadas diurnas sobre el AOI, se dispone típicamente de ventanas de visibilidad con la estación terrena del orden de 434 s para contactos operativos. Este valor se adopta como *ventana temporal disponible* para procesar a bordo y descargar las alertas, pero no como requisito estricto de latencia, que viene dado por el umbral de 5 minutos.

En el escenario de máxima carga (125 bloques por pasada), cada bloque de 9 km *along-track* se adquiere en 1,2 s, por lo que la ventana de 150 s sobre el AOI permite capturar secuencialmente los 125 bloques. El presupuesto total de cómputo para procesarlos es de 43,8 GFLOPs, que sobre una CPU dual-core Cortex-A9 a 800 MHz (3,2 GFLOPs efectivos) se traduce en unos 13,7 s de inferencia. Suponiendo una alerta ligera por bloque, de tamaño medio 11,5 kB, el volumen total de 125 alertas asciende a 1,44 MB, que a una tasa de enlace de 250 kbit/s (31,25 kB/s) se transmiten en aproximadamente 46 s.

En el peor caso, considerando un bloque capturado al final de la ventana de 150 s sobre el AOI, la latencia extremo a extremo sería del orden de:

$$T_{\text{e2e, peor}} \approx 150 \text{ s (captura)} + 13,7 \text{ s (inferencias)} + 46 \text{ s (downlink)} \approx 210 \text{ s,}$$

es decir, alrededor de 3,5 minutos. Este valor se sitúa ampliamente por debajo tanto del límite de 5 minutos fijado en la hipótesis de misión. Por tanto, desde el punto de vista temporal, la arquitectura propuesta de *edge computing* a bordo de un CubeSat 12U cumple holgadamente las restricciones de latencia extremo a extremo establecidas para el servicio ECaaS.

5. Conclusiones

A partir de los resultados obtenidos del análisis de la dinámica de vuelo, es posible establecer un marco temporal coherente para la validación de la hipótesis planteada. En particular, las ventanas de observación sobre el área de interés (AOI), con duraciones típicas del orden de 150 s, definen el intervalo disponible para la adquisición de imágenes, constituyendo la primera restricción operacional del sistema. Por otra parte, las ventanas de visibilidad con la estación terrena, con una duración promedio de aproximadamente 434 s para contactos operativos, establecen el margen temporal para la ejecución del procesamiento a bordo, la generación de alertas y su posterior transmisión antes de la pérdida de enlace.

La presencia de múltiples eventos de revisita sobre el AOI, junto con la ampliación de la franja de cobertura mediante un ángulo de apuntamiento de 40° de la cámara del satélite, permite garantizar una frecuencia de observación adecuada para aplicaciones de monitoreo continuo. Esta condición es fundamental para la determinación de susceptibilidad oportuna de eventos de ignición, ya que incrementa la probabilidad de captura dentro de ventanas temporales relevantes.

En conjunto, los parámetros derivados de la dinámica de vuelo demuestran que la misión dispone de ventanas temporales suficientes tanto para la adquisición de datos como para su procesamiento

y transmisión en órbita. Esto permite sostener que la integración de un modelo de *edge computing* a bordo de un CubeSat 12U es operacionalmente viable y consistente con el cumplimiento de una latencia extremo a extremo inferior a 5 minutos, dentro de una ventana media de visibilidad de aproximadamente 434 s con la estación terrena, validando así la hipótesis en términos de cobertura, acceso y restricciones temporales del sistema.

En relación al sensor electro-óptico a bordo, aunque la MultiScape100 CIS, desde el punto de vista de la capacidad de captura, dispone de una tasa de líneas suficiente para adquirir del orden de $2,1 \times 10^5$ líneas en una ventana de 150 s, la combinación de su geometría ($GSD = 5,2$ m, $swath = 21,3$ km) y la extensión del AOI fija un máximo práctico de unos 125 bloques operacionales de $9 \text{ km} \times 6 \text{ km}$ por pasada. Esta cota viene impuesta por la longitud along-track que cruza el AOI durante la ventana de visibilidad y no por la capacidad de cómputo a bordo, por lo que define el límite superior de escenas que el sistema puede alimentar al modelo de susceptibilidad de incendios en cada órbita y, en consecuencia, el techo de rendimiento del servicio ECaaS desde el punto de vista puramente sensor-geométrico.

Asimismo, del análisis temporal de la solución se puede deducir para la captura de la escena se dispone de 150 s en el área de cobertura, asimismo, para el procesamiento y transmisión de la alerta se tienen 434 s. Como se ha definido en el CONOPS, la captura de imágenes y/o escenas es independiente del procesamiento y transmisión de mensajes de alerta, lo cual implica que estos procesos puedan ejecutarse en paralelo y de manera simultánea.

Como tercera etapa de la misión, la transmisión de los mensajes dependerá de la velocidad del enlace de comunicaciones, tomando como referencia una velocidad de 250 kbit/s, y una tasa de transferencia de 100 mensajes de alerta en 37 s, con ello se ha determinado que cada alerta tiene un peso de 11,5 KB y se transmite en un tiempo de 370 ms.

Con estos datos, y los desempeños técnicos del sensor a bordo, tipo de procesador, enlaces de datos y consumo de cada uno de ellos y la plataforma se pudo determinar la implementación del procesamiento de inferencia de IA a bordo del satélite. En este sentido, se evaluó el uso de la SoC Xilinx de la familia Zynq 7000, la cual, a la luz de los cálculos para la validación del modelo de servicios ECaaS, se puede decir que:

- El presupuesto de cómputo del modelo TinyML (0,35 GMAC por bloque de 54 km^2) obtenido de la literatura como referencia para el servicio propuesto está ampliamente cubierto por la capacidad de la Zybo Z7-20, que proporciona 3,2 GFLOPS efectivos en CPU, resultando en tiempos de inferencia inferiores al requisito de 35 s.
- El ancho de banda de memoria (2,5 GB/s efectivos) y la capacidad de DDR3L de 1 GB permiten manejar sin problemas los ≈ 24 MB de datos crudos por bloque, de modo que la memoria no se convierte en cuello de botella para el flujo ECaaS.
- La combinación de ventana de captura (150 s), ventana de procesamiento y enlace 434 s y alertas compactas de 11,5 KB asegura que la latencia extremo a extremo (captura $\rightarrow$ inferencia $\rightarrow$ alerta en Tierra) se mantenga muy por debajo de los 5 min exigidos por la misión.

Por otra parte, el análisis del presupuesto de potencia muestra que, para un CubeSat 12U con generación solar efectiva de 64,8 W, 158,4 Wh de capacidad en baterías y criterio de operación con $SOC \geq 80\%$, la energía máxima utilizable por órbita se sitúa en torno a 95 Wh, lo que equivale a una potencia media disponible de unos 60 W. El modo de operación “Imaging-On + UHF” consume aproximadamente 41 W, dejando un margen de unos 19 W de potencia media específicamente asignable a la carga útil de *edge computing* durante la ventana de procesamiento. La inferencia del modelo de susceptibilidad, incluso asumiendo un consumo de 7 W durante 13,7 s (96 J, es decir, 0,027 Wh), se traduce en una potencia media de solo 0,22 W al distribuirse en los 434 s disponibles, muy por debajo del margen de 19 W y, por tanto, energéticamente despreciable frente al resto de la plataforma.

Por tanto, desde la perspectiva de validación del modelo de servicios ECaaS, se demuestra que es factible la implementación de este servicio basado en la nube, en específico ECaaS, basado en la tarjeta Zybo Z7-20 demuestra capacidad técnica suficiente, tanto en cómputo como en latencia y consumo energético, para sostener la inferencia a bordo necesaria para estimar de manera predictiva la susceptibilidad de focos de incendios forestales sobre el AOI definido, cumpliendo con el Concepto Operacional de misión de NGEN-MAWIDA.

Por tanto, desde la perspectiva de validación del modelo de servicios ECaaS, se demuestra que es factible la implementación de este servicio basado en la nube, en específico ECaaS, basado en la tarje-

ta Zybo Z7-20 demuestra capacidad técnica suficiente, tanto en cómputo como en latencia y consumo energético, para sostener la inferencia a bordo necesaria para estimar de manera predictiva la susceptibilidad de focos de incendios forestales sobre el AOI definido, cumpliendo con el Concepto Operacional de misión de NGEN-MAWIDA. En consecuencia, se confirma explícitamente el cumplimiento de los objetivos específicos OE1, OE2 y OE3 establecidos en el presente trabajo.

Referencias

1. Chantal Cappelletti, Simone Battistini, and Benjamin K. Malphrus. *CubeSat Handbook: From Mission Design to Operations*. 2020.
2. California Polytechnic State University. Cubesat design specification rev 14.1. *The CubeSat Program, Cal Poly SLO*, 8651, 2022.
3. Guoli Zhang, Ming Wang, and Kai Liu. Forest fire susceptibility modeling using a convolutional neural network for yunnan province of china. *International Journal of Disaster Risk Science*, 10:386–403, 2019.
4. John T Abatzoglou and A Park Williams. Impact of anthropogenic climate change on wildfire across western us forests. *Proceedings of the National Academy of sciences*, 113(42):11770–11775, 2016.
5. Ministerio del Medio Ambiente de Chile. Emisiones de Gases de Efecto Invernadero, 2025. [En línea; accedido: 31-oct-2025].
6. Oltjon Kodheli, Eva Lagunas, Nicola Maturo, Shree Krishna Sharma, Bhavani Shankar, Jesus Fabian Mendoza Montoya, Juan Carlos Merlano Duncan, Danilo Spano, Symeon Chatzinotas, Steven Kisseleff, Jorge Querol, Lei Lei, Thang X. Vu, and George Goussetis. Satellite communications in the new space era: A survey and future challenges, 2021.
7. Olfa Ben yahia, Eylem Erdogan, Gunes Karabulut Kurt, Ibrahim Altunbas, and Halim Yanikomeroglu. Haps selection for hybrid rf/fso satellite networks. *IEEE Transactions on Aerospace and Electronic Systems*, 2022.
8. International Telecommunication Union. *Handbook on Small Satellites*. ITU Publications, Geneva, Switzerland, 2023 edition, 2023.
9. D. Lindsay, S. S. Gill, D. Smirnova, and P. Garraghan. The evolution of distributed computing systems: from fundamental to new frontiers. *Computing*, 103(8):1581–1603, 2021.
10. P. H. Enslow. What is a ‘distributed’ data processing system? *Computer (Long Beach Calif)*, 11(1):13–21, 1978.
11. Andrew S. Tanenbaum and Maarten Van Steen. *Distributed Systems: Principles and Paradigms*. Pearson Prentice Hall, 2 edition, 2023.
12. G. Nagarajan and R.I. Minu, editors. *Edge Computing and Computational Intelligence Paradigms for the IoT*. IGI Global, Hershey, PA, USA, 2020.
13. H. Mitake, Y. Kinebuchi, A. Courbot, and T. Nakajima. Coexisting real-time os and general-purpose os on an embedded virtualization layer for a multicore processor. In *Proceedings of the 2011 ACM Symposium on Applied Computing*, pages 629–630, Taichung, Taiwan, March 2011. ACM.
14. Pete Warden and Daniel Situnayake. *TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers*. O’Reilly Media, 2020.
15. M. Kerr, S. Tonetti, S. Cornara, J. I. Bravo, R. Hinz, A. Latorre, F. Membibre, C. Solimini, S. Wiehle, H. Breit, B. Tings, O. Koudelka, F. Teschl, E. Magli, T. Bianchi, Andrea Migliorati, Paolo Motto Ros, Michele Caon, R. Freddi, M. Benetti, F. Milani, G. Curci, S. Fraile, L. Garcia, C. Marcos, and A. Fiengo. Eo-alert: A novel architecture for the next generation of earth observation satellites supporting rapid civil alerts. In *Proceedings of the 71st International Astronautical Congress (IAC) – The CyberSpace Edition*, Online, October 2020. International Astronautical Federation (IAF). Paper ID: IAC-20-D1.2.5.
16. Ahmed Saleem Mahdi and Sawsen Abdulhadi Mahmood. An edge computing environment for early wildfire detection. *Annals of Emerging Technologies in Computing (AETiC)*, 6(3):56–68, July 2022. License: CC BY 4.0.
17. Ministerio del Medio Ambiente de Chile. Informe del inventario nacional de chile 2020: Inventario nacional de gases de efecto invernadero y otros contaminantes climáticos 1990–2018. Technical report, Área de Mitigación e Inventarios de Contaminantes Climáticos, Oficina de Cambio Climático, Ministerio del Medio Ambiente, Santiago, Chile, December 2020. Coordinadora: Camila Labarca Wyneken.
18. Axis Communications. Detección temprana de incendios forestales con IA y Axis, 2025. [En línea; accedido: 2-nov-2025].
19. Hispasat. La tecnología satelital al servicio de la prevención y detección de incendios, 2024. [En línea; accedido: 2-nov-2025].
20. Dive.tech. Cellnex: Prevención de incendios, 2024. [En línea; accedido: 7-nov-2025].
21. Cloud Studio. Revolución en la seguridad contra incendios: Cloud studio y movitherm, March 2025. [En línea; accedido: 11-nov-2025].

22. Alexandra Bjânes, Rodrigo De La Fuente, and Pablo Mena. A deep learning ensemble model for wildfire susceptibility mapping. *Ecological Informatics*, 65:101397, 2021.
23. Marios Avgeris, Dimitrios Spatharakis, Dimitrios Dechouniotis, Nikos Kalatzis, Ioanna Roussaki, and Symeon Papavassiliou. Where there is fire there is smoke: A scalable edge computing framework for early fire detection. *Sensors*, 19(3):639, February 2019. Published: 3 February 2019.
24. Equipo del proyecto Copernicus-LAC Panamá Hackathon. Monitoreo y caracterización de incendios en colombia: Caso de estudio TOLIMA, 2024. [En línea; accedido: 2-nov-2025].
25. Piyush Jain, Sean C. P. Coogan, Sriram Ganapathi Subramanian, Mark Crowley, Steve Taylor, and Mike D. Flannigan. A review of machine learning applications in wildfire science and management. August 2020. Natural Resources Canada; University of Alberta; University of Waterloo.
26. United States Space Command. Space-track.org satellite catalog query: Norad_cat_id 38011. https://www.space-track.org/basicspacedata/query/class/satcat/NORAD_CAT_ID/38011/format/html/emptyresult/show, 2025. Access requires user registration.
27. James R. Wertz and Wiley J. Larson. *The Space Mission Analysis and Design Process*. 1991.
28. AI Solutions. Orbit architect: Interactive orbital geometry explorer and teaching tool, 2024. Accessed: 2026-05-15.
29. GomSpace. 12u platform kit. <https://gomspace.com/product/nanosat-12u-kit/>, 2026. Accessed: 2026-03-14.
30. R. O. Chávez, M. E. Castillo-Soto, K. Traipe, M. Olea, J. A. Lastra, and T. Quiñones. A probabilistic multi-source remote sensing approach to evaluate extreme precursory drought conditions of a wildfire event in central chile. *Frontiers in Environmental Science*, 10:865406, 2022.
31. U.S. Department of Agriculture. Fy 2014 annual performance report. Technical report, U.S. Department of Agriculture (USDA), Washington, DC, September 2014. Available online: <https://www.performance.gov/>.
32. Secom (Sección de Estadísticas). Resumen de ocurrencia y daño por comuna, 1985 – 2024. Technical report, CONAF (Centro Documentales de Estadísticas Históricas), mayo 2024. Accedido 2024-05-28.
33. Laura Parra García, Gianluca Furano, Max Ghiglione, Valentina Zancan, Ernesto Imbembo, and Christos Ilioudis. Advancements in onboard processing of synthetic aperture radar (sar) data: Enhancing efficiency and real-time capabilities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17:18625–18645, 2024. Published: 3 June 2024.
34. Gianluca Furano, Gabriele Meoni, Aubrey Dunne, David Moloney, Veronique Ferlet-Cavrois, Antonis Tavoularis, Jonathan Byrne, Leonie Buckley, Mihalís Psarakis, Kay-Obbe Voss, and Luca Fanucci. Towards the use of artificial intelligence on the edge in space systems: Challenges and opportunities. *IEEE Aerospace and Electronic Systems Magazine*, 2020.
35. Lorenzo Diana and Pierpaolo Dini. Review on hardware devices and software techniques enabling neural network inference onboard satellites. *Remote Sensing*, 16(21):3957, October 2024. CC BY 4.0.
36. Xilinx, Inc. *Zynq-7000 SoC Data Sheet: Overview (DS190)*. Xilinx, San Jose, CA, July 2018. Product Specification, DS190 (v1.11.1).
37. Sanaz Moghim and Majid Mehrabi. Wildfire assessment using machine learning algorithms in different regions. *Fire Ecology*, 20, 2024. Published: 3 December 2024.
38. Vos, J. and Dreijer, G. *xScape50 and xScape100 Product Range: User Manual*. Simera Sense, revision 5 edition, 2023.
39. The CubeSat Program, Cal Poly SLO. Cubesat design specification (1u-12u), 2022.
40. NASA CubeSat Launch Initiative. Cubesat 101: Basic concepts and processes for first-time cubesat developers. https://www.nasa.gov/sites/default/files/atoms/files/nasa_csli_cubesat_101_508.pdf, October 2017. Produced under contract by California Polytechnic State University (Cal Poly) CubeSat Systems Engineer Lab.

ANEXO A: CubeSat

El proyecto CubeSat, originado en 1999 gracias a la colaboración entre Jordi Puig-Suari de Cal Poly y Bob Twiggs de la Universidad de Stanford [39]. Fue concebido para democratizar el acceso al espacio. Su principal objetivo era reducir significativamente los costos y el tiempo de desarrollo asociados con los satélites, al mismo tiempo que se buscaba aumentar la frecuencia de los lanzamientos espaciales. Esta iniciativa sentó las bases para una nueva clase de satélites estandarizados, abriendo oportunidades para la investigación y la exploración espacial a un espectro más amplio de instituciones y empresas.

La seguridad y el éxito de las misiones CubeSat dependen en gran medida del compromiso de los desarrolladores con la implementación de prácticas de ingeniería sólidas y rigurosas. Es fundamental realizar pruebas exhaustivas y verificaciones exhaustivas de los sistemas para prevenir fallos que puedan poner en peligro la misión, dañar otros componentes de la carga útil o incluso comprometer el vehículo de lanzamiento. La fiabilidad de estos pequeños satélites es primordial para garantizar la integridad de todo el programa CubeSat.

La comunidad CubeSat, en su conjunto, tiene la responsabilidad de garantizar la operación segura de sus sistemas, cumpliendo con las regulaciones y requisitos establecidos. Al fomentar la compatibilidad con diversos dispensadores y oportunidades de lanzamiento, se maximiza el potencial de las misiones CubeSat y se promueve la innovación continua en el campo de la exploración espacial.




Figura 8. Formato dimensiones CubeSat [40].

El diseño de CubeSats se rige por estándares geométricos que garantizan la compatibilidad con los dispensadores comerciales y la operación segura en órbita como se muestra en la Figura 8. En 12U, las caras ortogonales +X, +Y y +Z presentan dimensiones nominales de 226.3 mm por lado, mientras que la longitud del conjunto en la dirección longitudinal es 366.0 mm. Estas cotas establecen el “envelope” externo y el volumen útil para la integración de subsistemas. Desde la interfaz mecánica, se prescriben márgenes y zonas de contacto: standoff mínimo de 6.5 mm en la cara +Z; zona libre asociada al riel con mínimo de 8.5 mm; rieles perimetrales entre 0.5 y 7.0 mm y espesor mínimo de 0.1 mm en las caras $\pm Z$; así como la posibilidad de protrusiones solamente en las caras habilitadas. El sistema de coordenadas se define en el centro geométrico del satélite, sirviendo de referencia para CAD, metrología y verificación.

Masa máxima y distribución de masa

El estándar limita la masa típica de un CubeSat 12U a 24.00 kg, condicionando la selección de materiales, la densidad de empaquetamiento y la arquitectura de subsistemas. El cumplimiento de este límite es clave para no exceder las capacidades del dispensador y para preservar márgenes de desempeño en lanzamiento y operación.

Variables inerciales: centro de gravedad y balance

La ubicación del centro de gravedad, medida desde el centro geométrico, debe permanecer dentro de bandas estrictas para asegurar estabilidad estructural y control actitudinal: ± 4.5 cm en los ejes X e Y, y ± 7 cm en el eje Z para la configuración 12U. Estos rangos minimizan momentos desbalanceados sobre el dispensador, favorecen respuestas modales predecibles frente a vibración y cargas cuasiestáticas, y mantienen la autoridad del sistema de control de actitud ante perturbaciones. En síntesis, el desempeño del 12U descansa en la coherencia entre envelope geométrico, interfaz de rieles y balance inercial, cuyo

Configuración [U]	Masa [kg]
1U	2.00
1.5U	3.00
2U	4.00
3U	6.00
6U	12.00
12U	24.00

Tabla 3. Especificaciones de masa para CubeSat [39]

cumplimiento estricto es condición necesaria para una integración segura y una operación fiable en vuelo.

	X Axis	Y Axis	Z Axis
1U	+2 cm / -2 cm	+2 cm / -2 cm	+2 cm / -2 cm
1.5U	+2 cm / -2 cm	+2 cm / -2 cm	+3 cm / -3 cm
2U	+2 cm / -2 cm	+2 cm / -2 cm	+4.5 cm / -4.5 cm
3U	+2 cm / -2 cm	+2 cm / -2 cm	+7 cm / -7 cm
6U	+4.5 cm / -4.5 cm	+2 cm / -2 cm	+7 cm / -7 cm
12U	+4.5 cm / -4.5 cm	+4.5 cm / -4.5 cm	+7 cm / -7 cm

Tabla 4. Rangos aceptables del centro de gravedad especificados a partir del centro geométrico de cada eje [39]

ANEXO B: Estimación del consumo y presupuesto de potencia

Con el objetivo de estimar el presupuesto de potencia disponible para la carga útil de *edge computing* se analizarán las pasadas del satélite en la cobertura nacional y con ello los sistemas en funcionamiento para la operación de susceptibilidad de incendios forestales.

La tabla 5 representa el resultado del comando “ContactLocator1” como el tiempo de conexión entre el satélite en órbita y la estación terrena. La configuración se basa en órbitas entre las fechas definidas aleatoriamente desde el 16 al 19 de enero 2025.

Tabla 5. Tiempo de visibilidad del satélite con la estación terrena satelital

Start Time (UTC)	Stop Time (UTC)	Duration (s)
16 Jan 2025 00:33:38.743	16 Jan 2025 00:40:48.252	429.50876687
16 Jan 2025 02:07:50.399	16 Jan 2025 02:15:09.806	439.40767623
16 Jan 2025 11:16:31.228	16 Jan 2025 11:17:55.434	84.205995058
16 Jan 2025 12:46:39.400	16 Jan 2025 12:55:19.176	519.77671261
17 Jan 2025 00:23:04.758	17 Jan 2025 00:29:39.600	394.84259313
17 Jan 2025 01:56:52.281	17 Jan 2025 02:04:35.690	463.40887657
17 Jan 2025 12:35:49.413	17 Jan 2025 12:44:31.534	522.12101285
18 Jan 2025 00:12:35.055	18 Jan 2025 00:18:25.904	350.84868665
18 Jan 2025 01:45:56.056	18 Jan 2025 01:53:58.876	482.81995710
18 Jan 2025 12:25:01.532	18 Jan 2025 12:33:42.534	521.00190839
19 Jan 2025 00:02:11.807	19 Jan 2025 00:07:04.980	293.17350788
19 Jan 2025 01:35:01.488	19 Jan 2025 01:43:19.617	498.12962625
19 Jan 2025 12:14:15.742	19 Jan 2025 12:22:52.195	516.45298699
19 Jan 2025 23:52:00.616	19 Jan 2025 23:55:31.211	210.59497520

Por otra parte, el tiempo de acceso de las órbitas al AOI se obtienen configurando en el software GMAT el comando “ContactLocator2”, el cual determina la intersección entre las órbitas del satélite con el AOI de coordenadas que se muestran en la Tabla 6.

Tabla 6. Coordenadas de puntos (lat/long)

Punto	Latitud	Longitud
1	41,2722	-77,3746
2	41,5872	-68,3933
3	32,4679	-66,5701
4	32,9938	-75,2497

Los resultados del comando “ContactLocator2” se muestran en la Tabla 7.

Tabla 7. Eventos de revisita de la misión satelital en la zona de captura del AOI.

Start Time (UTC)	Stop Time (UTC)	Duration revisita (s)
16 Jan 2025 12:49:49.387	16 Jan 2025 12:52:18.661	149,274 170 84
17 Jan 2025 12:38:58.878	17 Jan 2025 12:41:27.767	148,889 303 18
18 Jan 2025 12:28:08.000	18 Jan 2025 12:30:36.468	148,467 256 34
19 Jan 2025 12:17:16.751	19 Jan 2025 12:19:44.759	148,007 485 27
20 Jan 2025 01:27:22.188	20 Jan 2025 01:28:11.299	49,110 851 227
20 Jan 2025 12:06:25.128	20 Jan 2025 12:08:52.638	147,509 051 42
21 Jan 2025 01:16:27.187	21 Jan 2025 01:18:08.914	101,727 846 06
22 Jan 2025 01:05:32.640	22 Jan 2025 01:08:07.835	155,194 855 76
23 Jan 2025 00:54:38.539	23 Jan 2025 00:57:12.106	153,567 424 18
24 Jan 2025 00:43:44.876	24 Jan 2025 00:46:16.796	151,920 373 30
25 Jan 2025 00:33:30.951	25 Jan 2025 00:35:21.899	110,948 492 33
26 Jan 2025 00:23:38.548	26 Jan 2025 00:24:27.409	48,860 588 553
29 Jan 2025 12:03:35.889	29 Jan 2025 12:06:05.414	149,524 143 08

La figura 9 representa un gráfico en el cual se representa el tiempo de funcionamiento de cada subsistema durante una pasada del satélite por territorio nacional y por consiguiente sobre la zona

de captura y el AOI. Se puede apreciar que las funciones de base del satélite se mantienen, estas son la funciones del computador de a bordo, el computador para coordinar las cargas útiles, la recepción de telecomandos desde la estación principal en tierra. Dentro de la ventana de visibilidad el satélite comenzará a ejecutar la planificación y ajustará su actitud para la captura de imágenes a partir de T1. Entre T1 y T2, aún no habrá imágenes capturadas y por lo tanto ningún producto ni alertas que generar con la carga útil de *edge computing*. Una vez generada la primera escena, a partir de T2, se comienzan a capturar las primeras imágenes y junto con ello el procesamiento de *edge computing* comenzará a ejecutar el modelo de inferencia y transmitir alertas. A momento de alcanzar T3, el satélite y por ende la cámara ya habrá salido de la zona de captura donde solo quedará en ejecución los procesos de inferencia y transmisión de alertas. Finalmente en T4, el satélite habrá salido de cobertura finalizando los procesos asociados a la ejecución de inferencia y alertas. Como se puede apreciar del gráfico, no se cuenta la ventana completa desde T1 hasta T4 para la inferencia, sino, desde que se generan las imágenes lo cual comienza desde T2, por lo tanto tomando como referencia Tmedio como el centro común se determinó que T2 a T4 es equivalente a 292 s.




Figura 9. Grafica de la pasada del satélite sobre cobertura de la zona de captura y AOI.

Datos

$$T_2 - T_3 = 150 \text{ s}$$

$$T_1 - T_4 = 434 \text{ s}$$

$$T_1 - T_{\text{medio}} = 217 \text{ s}$$

$$T_2 - T_{\text{medio}} = 75 \text{ s}$$

Cálculos:

$$T_2 - T_1 = 217 - 75 = 142 \text{ s}$$

$$T_4 - T_2 = 434 - 142 = 292 \text{ s}$$

Resultado:

$$T_2 - T_4 = 292 \text{ s}$$

Respecto del consumo de los satélites este varía de acuerdo con el modo de operación. En el modo “Imaging – On” el satélite activa la cadena completa de imagen, incluyendo el modo de consumo “imaging” y el “Payload OBC”, lo que eleva la potencia a aproximadamente 37 W sobre la plataforma base, con un factor de generación reducido a 0.8 debido al apuntamiento requerido durante la adquisición [29]. Este modo se emplea únicamente durante ventanas breves de toma de datos, limitadas operacionalmente a un máximo de 5 escenas por órbita para cumplir las restricciones de consumo y vida de

batería. Respecto del enlace UHF no constituye un modo operativo independiente sino un equipo que se activa solo en fases concretas de la misión. La tabla de consumos recoge explícitamente el transceptor UHF, con una potencia máxima de 4 W cuando está en transmisión [29]. Su uso se reserva a ventanas específicas (por ejemplo, commissioning, contingencias o servicios store and forward y UHF a terminales de usuario), y en esos periodos el perfil de potencia se recalcularía añadiendo sus 4 W sobre el modo base correspondiente, manteniendo el resto de factores de generación y tiempos de uso; fuera de esas ventanas, el sistema se dimensiona asumiendo el UHF apagado para no penalizar el margen de potencia ni la vida de batería [29].

En el modo **Imaging-On** el satélite mantiene operativo el enlace de telecomando en banda S mediante el transceptor en recepción continua, aportando un consumo específico de 0.69 W que ya está incluido dentro del presupuesto total de unos 37 W asignado a este modo [29].

Además de los modos operativos asociados a imagen y comunicaciones, el sistema AOCS se considera de forma independiente en el presupuesto de potencia debido a su rol continuo en el control de actitud. El AOCS, basado en el conjunto de sensores y actuadores (ruedas de reacción, magnetorquers, FSS, GNSS y, star tracker), permanece activo para garantizar el apuntamiento al Sol en modos SUNPOINTING, la estabilización durante eclipse y las maniobras de cambio de actitud entre nadir, GS-pointing y otros modos definidos en la FSM del control [29]. Por lo tanto, su consumo como un bloque común presente en prácticamente todos los modos nominales, de manera que cualquier está considerado el consumo de este subsistema en el modo “imaging-on”.

En resumen, el modo **Imaging-On**, el presupuesto de potencia de la plataforma es de **37,11 W** [29]. Este valor ya incluye:

- El **AOCS** funcionando de manera continua (OBC ADCS, sensores y actuadores asociados).
- El **enlace de telecomando** en banda S en recepción continua (modo RX), con **0.69 W** incluidos dentro de esos 37,11 W [29].

Si se añade el **UHF** (no contemplado en ese modo nominal y que se modela como una carga adicional de 4 W sobre la plataforma), el consumo total pasa a ser aproximadamente:

$$P_{\text{total}} \approx 37,11 \text{ W} + 4 \text{ W} = 41,1 \text{ W}$$

Por tanto, para **Imaging-On + UHF**, considerando AOCS continuo y S-band en recepción, el consumo total es del orden de **41 W**.

Desde el punto de vista de la provisión de energía, el sistema de generación y gestión de potencia del CubeSat está basado en su fuente de poder y dos tipos de arreglos solares: dos alas desplegables con seguimiento solar (hasta 90 W totales) y paneles en el cuerpo del satélite como opción complementaria [29]. La energía generada por los paneles entra al Array Conditioning Unit (ACU), que dispone de 2×6 convertidores para maximizar el punto de operación de las cadenas solares y regular la tensión hacia el bus y las baterías [29]. Desde ahí, la potencia se gestiona en la Power Management Unit (PMU), que controla modos de potencia según el voltaje de batería, el control de despliegues y la carga de las dos baterías (2×86 Wh, 28.8 V nominal, conectables en paralelo), mientras que la Power Distribution Unit (PDU) entrega la energía a los distintos subsistemas mediante canales de baja y alta tensión con protección frente a latch-up. En el modo **Imaging-On + UHF**, los paneles (con un factor de actitud de generación de 0.8 para Imager-On) suministran energía de forma continua durante el tramo iluminado de la órbita; esta energía alimenta directamente la carga de plataforma y carga útil (ADCS, OBCs, telecomando en banda S en RX, cámara en modo imaging, OBC, etc.) y, cuando hay superávit respecto al consumo instantáneo, el excedente se utiliza para recargar las baterías. El consumo de la operación **Imaging-On** de la plataforma es de 37,11 W, que ya incluye el AOCS y el AX2150 en modo RX (0.69 W), y al activar el UHF AX100 (4 W) se elevan los consumos de bus hasta unos 41 W de orden de magnitud [29]. Durante eclipse, toda la energía consumida (tanto de la plataforma base como del modo **Imaging-On** si se solapa, y del UHF si se programa en esa fase) proviene exclusivamente de las baterías, manteniendo los buses regulados según las eficiencias asumidas y los márgenes de degradación celular y de capacidad de batería a lo largo de la misión, por lo que la planificación (ej. limitar a 5 imágenes por órbita) asegura que el balance generación-consumo mantenga el estado de la carga y baterías dentro de los límites requeridos para la vida útil de 5 años [29].

Tabla 8. Presupuesto de potencia de la plataforma

Ítem	Parámetro	Valor
Consumo	“Imaging-On”	37,11 W
	UHF	4 W
	“Imaging-On + UHF”	41,11 W
Generación EPS	Potencia solar BOL	90 W
	Factor de actitud en “Imager-On”	0,8
	Potencia solar geométrica en “Imager-On”	72 W
	Eficiencia regulador strings→batería/bus	90 %
	Potencia neta disponible	64,8 W
Balance (día)	Margen instantáneo aprox.	23,7 W
Eclipse	Factor de generación en eclipse	0
Batería	Capacidad batería @BOL	158,4 Wh

En la Tabla 8, se muestran los consumos de potencia y generación de energía conforme a ello se determinará el presupuesto de potencia disponible para el consumo máximo de la carga útil de *edge computing*. Para no bajar del 80 % (margen para mantener SOC) de capacidad de batería en una órbita en peor caso (36 min de eclipse y ~ 59 min de iluminación)¹, la condición básica es:

$$E_{\text{consumo, órbita}} \leq E_{\text{generada, órbita}} + 0,2 E_{\text{bat}}$$

Con los valores de la plataforma CubeSat:

- Capacidad total de baterías @BOL: $E_{\text{bat}} = 158,4 \text{ Wh}$
- Potencia solar BOL: 90 W; factor actitud típico 0,8–0,95; eficiencia 90 %

En peor caso de generación (modo Imaging-On, factor 0,8):

$$P_{\text{gen,eff}} \approx 90 \text{ W} \times 0,8 \times 0,9 \approx 64,8 \text{ W}$$

Con ~ 59 min de iluminación por órbita¹:

$$E_{\text{gen, órbita}} \approx 64,8 \text{ W} \times \frac{59}{60} \text{ h} \approx 63,7 \text{ Wh}$$

Para no bajar del 80 %:

$$E_{\text{consumo, órbita}}^{\text{máx}} \approx 63,7 \text{ Wh} + 0,2 \cdot 158,4 \text{ Wh} \approx 63,7 + 31,7 \approx 95,4 \text{ Wh}$$

Es decir, el modo de operación definido para la órbita completa no debería superar del orden de 95 Wh por órbita si quieres garantizar que el SOC no baje del 80 % incluso en peor caso de sol.

El límite como potencia media por órbita quedará:

$$P_{\text{medio, órbita}}^{\text{máx}} \approx \frac{95,4 \text{ Wh}}{95 \text{ min}/60} \approx 60 \text{ W}$$

En resumen:

- **Energía máxima consumible por órbita** para no bajar del 80 % SOC: **$\sim 95 \text{ Wh/órbita}$** en peor caso.
- **Potencia media máxima** del modo de operación de órbita: **$\sim 60 \text{ W}$** .

De lo anterior y el consumo calculado para el modo de “imaging on y UHF” nos deja un margen de presupuesto de potencia disponible en torno a los de 19 W.

- Modo Imaging + UHF:

$$E_{\text{Ing+UHF, órbita}} = 41,11 \text{ W} \times \frac{95}{60} \text{ h} \approx 65,1 \text{ Wh}$$

- Margen de energía por órbita:

$$E_{\text{margen, órbita}} \approx 95,4 - 65,1 \approx 30,3 \text{ Wh}$$

- Potencia media máxima admisible para $\text{SOC} \geq 80\%$:

$$P_{\text{medio, máx}} \approx \frac{95,4 \text{ Wh}}{95 \text{ min}/60} \approx 60 \text{ W}$$

- Margen de potencia media sobre el modo Imaging + UHF:

$$P_{\text{margen}} \approx 60 - 41,11 \approx 18,9 \text{ W}$$

Energía consumible por carga adicional en la ventana de 5 minutos:

$$E_{\text{proc, rbita}} = P_{\text{proc}} \left(\frac{5}{60} \right) \text{ h}$$

Con $P_{\text{proc}} \approx 19 \text{ W}$,

$$E_{\text{proc, órbita}} = P_{\text{proc}} \left(\frac{5}{60} \right) \text{ h} = 19 \times 0,0833 \text{ h} \approx 1,58 \text{ Wh}$$

Por tanto, si la carga de procesamiento corre simultáneamente durante esos 5 minutos,

$$E_{\text{proc, órbita}} \approx 1,6 \text{ Wh}$$

De las ecuaciones y estimaciones previas efectuadas, se determinó que la potencia máxima disponible para la carga útil de *edge computing* es de **19 W** con un límite de energía consumible de **1,6 Wh**.

Glosario

- campo de visión (FOV)** Ángulo máximo que abarca el sistema óptico de un sensor, que determina el área instantánea de terreno observada en cada adquisición. 16
- carga útil (payload)** Conjunto de instrumentos y equipos de un satélite dedicados directamente a los objetivos de la misión, como sensores ópticos, hiperspectrales o térmicos, y subsistemas asociados. 3
- CubeSat 12U** Satélite pequeño que sigue el estándar CubeSat, con un volumen equivalente a doce unidades de 10×10×10 cm y masa típica de decenas de kilogramos, apto para cargas útiles de observación de la Tierra. 3
- edge computing** Paradigma en el que el procesamiento de datos se realiza cerca de la fuente que los genera (sensores, cámaras, satélites), reduciendo latencia y volumen de información enviada a la nube. 1
- Índice de Vegetación de Diferencia Normalizada (NDVI)** Índice espectral que mide el vigor y la actividad fotosintética de la vegetación. 8
- modelo de susceptibilidad** Modelo estadístico o de aprendizaje automático que estima, para cada celda del territorio, la probabilidad de ocurrencia o ignición de incendios a partir de variables explicativas espaciales. 4
- pipeline** Secuencia de etapas que siguen los datos desde su adquisición hasta la obtención de una predicción en el dispositivo de borde, incluyendo preprocesamiento, inferencia del modelo y post-procesamiento. 4
- rede neuronales convolucionales (CNN)** Red neuronal convolucional entrenada con variables espaciales y registros históricos de incendios para estimar la probabilidad de ignición en cada píxel del territorio. 8
- susceptibilidad de ignición de incendios forestales** Probabilidad de que un determinado combustible vegetal se encienda y origine un incendio, en función de las condiciones de vegetación, topografía, clima y factores antrópicos. 1
- swath** Ancho de barrido o ancho de la franja de superficie terrestre cubierta por el sensor en una pasada orbital, derivada del campo de visión y de la altura de la órbita. 21
- tiles** Subconjunto rectangular de una imagen o mapa tratado como unidad básica de cálculo para organizar, paralelizar y escalar el procesamiento. 9
- Tiny Machine Learning (TinyML)** Subárea del aprendizaje automático centrada en el diseño y despliegue de modelos en dispositivos con recursos muy limitados, como microcontroladores y nodos IoT. 8
- Índice de Quemado Normalizado (NBR)** Índice espectral utilizado para resaltar áreas quemadas y evaluar su severidad. 9
- Índice Meteorológico de Peligro de Incendios (FWI)** Sistema de índices meteorológicos que integra temperatura, humedad, viento y precipitación para cuantificar el peligro de incendio y su posible intensidad. 10
- órbita baja heliosíncrona** Órbita terrestre baja casi polar en la que el satélite pasa sobre un punto dado aproximadamente a la misma hora solar local, proporcionando condiciones de iluminación comparables en sucesivas pasadas. 4

Siglas

ADCS Attitude Determination and Control System. 5

AOCS Attitude and Orbit Control System. 5

AOI Área de Interés. 5

CNN Convolutional Neural Network. 1

ECaaS Edge Computing as a Service. 4

FWI Fire Weather Index. 4

GMAT General Mission Analysis Tool. 19

GSD Ground Sample Distance. 17

IRD Ignition Raster Dataset. 8

ISS International Space Station. 3

LEO Low Earth Orbit (órbita terrestre baja). 4

ML Machine Learning. 7

SAR Synthetic Aperture Radar. 9

SDN Software Defined Networking. 7

SNSat Sistema Nacional Satelital. 1

TT&C Telemetry, Tracking and Control. 19

UTCUTS Uso de la Tierra, Cambio de Uso de la Tierra y Silvicultura. 4

VRD Variable Raster Dataset. 8