



ONU-HABITAT



INVENTARIO AUTOMATIZADO DE ASENTAMIENTOS PRECARIOS EN CENTROAMÉRICA Y REPÚBLICA DOMINICANA



PROGRAMA DE LAS NACIONES UNIDAS PARA LOS ASENTAMIENTOS HUMANOS (ONU-HABITAT)

Inventario Automatizado de Asentamientos Precarios en Centroamérica y República Dominicana.
Todos los derechos reservados © 2025

Aviso legal

Las denominaciones empleadas y la presentación del material en esta publicación no implican la expresión de opinión alguna por parte de la Secretaría de las Naciones Unidas sobre la condición jurídica de ningún país, territorio, ciudad o zona ni de sus autoridades, ni sobre la delimitación de sus fronteras o límites en relación con su sistema económico o grado de desarrollo. Se permite la reproducción de extractos sin autorización, siempre que se indique la fuente. Las opiniones expresadas en esta publicación no reflejan necesariamente las del Programa de las Naciones Unidas para los Asentamientos Humanos, las Naciones Unidas y sus Estados Miembros.

www.onu-habitat.org

CRÉDITOS

ONU-HABITAT

Coordinación

- Anacláudia Marinheiro Centeno Rossbach
Directora Ejecutiva
- Elkin Velásquez Monsalve
Director Regional para América Latina y el Caribe
- Fernanda Lonardoni
Jefa de la Oficina de ONU-Habitat
Subregión de México, Cuba y Centroamérica
- Eugenia De Grazia
Oficial de programa
- Claudia Nataly Mondragón Rivera
Especialista en urbanismo
- María Elena Espinoza Hernández
Especialista en Planificación Territorial y Sistemas de Información Geográfica

Equipo técnico del proyecto

- Bryan Rene Alvarado Hernández
Especialista en Tecnologías de la Información
- José Juan Medina Cardona
Especialista en Economía Urbana y Sistemas de Información Geográfica
- Brenda Patricia Torres Porras
Analista Técnico en Sistemas de Información Geográfica
- Marco Muñoz González
Analista Técnico en Planeación, Indicadores Urbanos y Sistemas de Información Geográfica
- Daniela Núñez Ruiz
Analista en Desarrollo de Programas y Proyectos

Diseño editorial

- Silvia Guadalupe Espinosa Castillo
Analista en comunicación digital

INSTITUCIONES ALIADAS

- UNITAC
Gesa Ziemer; Sophie Naue y Michael Hathorn
- IDB
Washington Meneses Fajardo; Antonio Vázquez Brust y Scetta María De Los Angeles
- GIZ
Abner Jiménez

Agradecimientos especiales

- A funcionarios del gobierno nacional, metropolitano y/o local de los países de la región SICA que colaboraron para la consolidación del Inventario Automatizado de Asentamientos Precarios en Centroamérica y República Dominicana.
- Belice: Belmopan City Council; Ministry of Infrastructure Development and Housing; Ministry of Rural Transformation, Community Development, Labour and Local Government.
- Costa Rica: Ministerio de Vivienda y Asentamientos Humanos; Municipalidad de San José de Costa Rica.
- El Salvador: Oficina de Planificación del Área Metropolitana de San Salvador (OPAMSS); Alcaldía de San Salvador Centro; Alcaldía de San Salvador Sur; Alcaldía de la Libertad Este; Alcaldía de la Libertad Sur; Distrito de Cuscatancingo; Distrito Ciudad Delgado; Ministerio de Vivienda de El Salvador.
- Guatemala: Empresa Metropolitana de Vivienda y Desarrollo Urbano (EMVDU); Municipalidad de Guatemala.
- Honduras: Secretaría de Gobernación, Justicia y Descentralización (SGJD), Secretaría de Planificación Estratégica (SPE), Programa de Vivienda y Asentamientos Humanos de Honduras (PVAH).
- Nicaragua: Ministerio de Relaciones Exteriores de la República de Nicaragua, Instituto Nicaragüense de Vivienda Urbana y Rural (INVUR), Municipalidad de Managua, Nicaragua.
- Panamá: Ministerio de Vivienda y Ordenamiento Territorial (MIVIOT).
- República Dominicana: Municipalidad de Santo Domingo, República Dominicana; Ministerio de Vivienda Hábitat y Edificaciones.

CONTENIDOS

1	Introducción	6
2	Precariedad en Centroamérica y República Dominicana	8
3	Ruta crítica para la consolidación del IAAP	12
	3.1. Etapa 1: Consideraciones preliminares	13
	3.1.1. Definición de las ciudades objetivo	13
	3.1.2. Identificación de indicadores funcionales	14
	3.1.3. Definición de la muestra de Asentamientos Precarios conocidos	15
	3.2. Etapa 2: Modelado (machine learning)	18
	3.2.1. Adquisición y tratamiento de imágenes satelitales	18
	3.2.2. Programación y desarrollo del algoritmo	20
	3.2.3. Entrenamiento del algoritmo	21
	3.2.4. Aplicación del modelo y generación de resultados iniciales	22
	3.3. Etapa 3: Identificación y caracterización de Asentamientos Precarios (gestión)	23
	3.3.1. Análisis de resultados post-procesamiento	23
	3.3.2. Comparación con datos y línea base	24
	3.3.3. Estrategia participativa para la revisión de resultados	25
	3.3.4. Caracterización inicial: aproximación al número de edificaciones o viviendas en los asentamientos precarios	26
	3.3.5. Generación del inventario preliminar	27
	3.4. Etapa 4: Consolidación y socialización de inventario automatizado de Asentamientos Precarios (IAAP)	28
	3.5. Etapa 5: Verificación en Campo y Validación Final por parte de los gobiernos locales	28
4	Resultados obtenidos	30
	4.1. Ciudades de Belice y Belmopán	32
	4.2. Gran Área Metropolitana de San José	36
	4.3. Área Metropolitana de San Salvador	40
	4.4. Zona Metropolitana de la Ciudad de Guatemala	44
	4.5. Zona Metropolitana Distrito Central (Tegucigalpa y Comayagüela)	48
	4.6. Región Metropolitana de Managua	52
	4.7. Área Metropolitana de Panamá	56
	4.8. Zona Metropolitana de Santo Domingo	60
5	Conclusiones y recomendaciones	64
	5.1. Impacto del IAAP en la región SICA	65
	5.2. Una base de datos para informar políticas públicas eficaces	66
6	Referencias	68
7	Anexos	72
	7.1. Detalles técnicos del <i>UNAIPS Methodology</i>	72
	7.2. Detalles técnicos del algoritmo <i>BEAM</i>	77

1. INTRODUCCIÓN

El acceso a una vivienda adecuada es un desafío global. En el mundo, más de 1,800 millones de personas carecen de una vivienda adecuada y el número de quienes residen en asentamientos precarios supera los 1,000 millones¹. Esto equivale a casi una cuarta parte de la población urbana mundial, que con frecuencia enfrenta la falta de servicios básicos, la obligación de habitar en zonas propensas a desastres naturales y las tierras más vulnerables, además de estar expuesta a desalojos forzosos.

En la región del Sistema de la Integración Centroamericana (SICA), la crisis de la vivienda se manifiesta en una urbanización acelerada y el crecimiento descontrolado de los asentamientos precarios. Los países que integran esta región comparten desafíos estructurales comunes, como la exposición a desastres naturales, desigualdades persistentes, déficits en infraestructura urbana y la **falta de datos actualizados sobre las condiciones habitacionales**. La carencia de información precisa y actualizada, incluyendo el número de personas en situación de vulnerabilidad, la disponibilidad de suelo y el estado de los asentamientos, limita la capacidad de los gobiernos y las organizaciones sociales para diseñar políticas públicas efectivas que aborden la crisis.

Bajo este contexto y en el marco del programa regional *Contribución a la implementación de la Nueva Agenda Urbana y la recuperación postpandémica en Centroamérica y República Dominicana*, ejecutado entre 2022 y 2024, ONU-Habitat y la Agencia Suiza de Cooperación para el Desarrollo (COSUDE) unieron esfuerzos para desarrollar el **Inventario Automatizado de Asentamientos Precarios (IAAP)**. Su objetivo principal es **generar un mapa y base de datos confiable y actualizada de los asentamientos precarios de las principales ciudades de la región** para promover la planificación urbana eficiente y la formulación de políticas públicas efectivas con enfoque integral de combate a la pobreza, la desigualdad y la crisis de vivienda de la región.

El **IAAP** es una iniciativa estratégica innovadora que contó con el apoyo del Acelerador de Tecnologías de Innovación de las Naciones Unidas para las ciudades (UNITAC) que en conjunto con ONU-Habitat emplearon **tecnologías innovadoras basadas en Inteligencia Artificial (IA) y Sistemas de Información Geográfica (SIG)** para mapear con precisión las áreas más vulnerables en las ciudades de Tegucigalpa (Honduras), Guatemala (Guatemala), Belice y Belmopán (Belice), Panamá (Panamá), San José (Costa Rica), San Salvador (El Salvador), Managua (Nicaragua) y Santo Domingo (República Dominicana).

El uso de tecnologías emergentes, como algoritmos de entrenamiento y aprendizaje automático, análisis de imágenes satelitales y sistemas de información geográfica, aportaron un valor significativo al proyecto. El algoritmo MAIIA (BID, 2022) sirvió como punto de referencia para la definición del proceso y metodología propia de ONU-Habitat ([UNAIPS Methodology](#)) que posibilita mapear asentamientos precarios de manera precisa y eficiente, reduciendo costos y tiempos en comparación con métodos tradicionales. **Su desarrollo se logró con apoyo de funcionarios locales de las ciudades analizadas que proveyeron de una muestra de asentamientos precarios conocidos, base de la programación, entrenamiento y detección sobre imágenes de satélite de alta resolución. Esta herramienta impulsa el enfoque desarrollo centrado en las personas** (UN-Habitat 2022, 2024) al generar información de asentamientos vulnerables que sirvan de referencia para la toma de decisiones e implementación de soluciones inclusivas y adaptadas al contexto por parte de los funcionarios locales.

El documento se organiza en varias secciones, comenzando con un marco conceptual que define los términos clave relacionados con los asentamientos precarios y los criterios utilizados para su identificación. Enseguida, se detalla la metodología empleada, desde el diseño del proceso hasta las fuentes de información utilizadas y los pasos técnicos implementados, como el

entrenamiento del algoritmo, la validación participativa y la generación de polígonos de asentamientos precarios. Los resultados del proyecto se presentan en términos de estadísticas y mapas por ciudad, junto con aprendizajes clave derivados de talleres y actividades de campo, ofreciendo diferentes recomendaciones para futuras implementaciones. Finalmente, el documento concluye subrayando el impacto potencial del IAAP en la región y su posible contribución a la generación de políticas públicas más inclusivas, complementado con anexos que profundizan sobre aspectos técnicos y herramientas utilizadas.

El IAAP no sólo responde a desafíos locales, sino que también se alinea con la Agenda 2030 y los Objetivos de Desarrollo Sostenible (ODS), la Nueva Agenda Urbana (NAU) y el Plan Estratégico de ONU-Habitat 2026-2029, **“Vivienda adecuada, suelo y servicios básicos para todos”**. Este proyecto también reafirma en los compromisos establecidos en el **Pacto del Futuro y el llamado a la Acción de El Cairo**, adoptados en 2024 durante la Cumbre del Futuro y el Foro Urbano Mundial 12. Estos acuerdos subrayan la necesidad de priorizar el derecho a una vivienda adecuada como pilar de la dignidad, la protección social y el desarrollo sostenible, al tiempo que se aprovechan las tecnologías digitales para diseñar soluciones innovadoras, contextualizadas y centradas en las personas.

¹ Ver <https://unstats.un.org/sdgs/report/2019/goal-11>

2. PRECARIEDAD EN CENTROAMÉRICA Y REPÚBLICA DOMINICANA

En la región de Centroamérica y la República Dominicana, los asentamientos precarios e informales representan una problemática urbana compleja y de gran envergadura, ya que afecta a millones de personas. De acuerdo con datos de la Comisión Económica para América Latina y el Caribe (CEPAL) (2012) y del Banco Mundial (2018), aproximadamente, 30% de la población urbana en estos países reside en condiciones de asentamientos informales o precarios. Sin planificación adecuada, estos espacios carecen de infraestructura básica, acceso a servicios esenciales y, en muchos casos, se localizan en áreas expuestas a fenómenos naturales extremos, configurando una condición de alta vulnerabilidad, lo que agrava la situación y pone en riesgo la seguridad y calidad de vida de sus habitantes.

Los factores con los que se asocia la proliferación de estos asentamientos en la región son la rápida urbanización y el crecimiento demográfico descontrolado, procesos que han superado la capacidad de las autoridades para proporcionar una planificación y gestión urbana efectiva. La falta de políticas públicas integrales, la pobreza generalizada y la informalidad laboral también contribuyen a la expansión de estos asentamientos, donde las personas construyen viviendas de forma espontánea y sin garantías legales ni de seguridad.

La relevancia de esta problemática ha suscitado la atención de organismos internacionales especializados en el desarrollo urbano, como el Programa de las Naciones Unidas para los Asentamientos Humanos (ONU-Habitat) (2016) y la Organización Panamericana de la Salud (OPS) (2019), quienes abogan por soluciones sostenibles y políticas de inclusión social que promuevan la regularización de estos asentamientos y mejoren la calidad de vida de sus habitantes. Asimismo, y, en concordancia con el ODS 11 que busca **“lograr que las ciudades sean inclusivas, seguras, resilientes y sostenibles”**, promueven la adopción de estrategias que integren la participación de la comunidad, la mejora de infraestructuras y servicios básicos, así como una adecuada planificación territorial, como aspectos prioritarios y fundamentales para abordar esta problemática, lograr ciudades más equitativas y resilientes en la región y para focalizar los esfuerzos y recursos adecuadamente.

Sin embargo, es preciso reconocer que, a nivel mundial, existen diversas visiones y terminologías para nominar, clasificar, caracterizar e identificar a los asentamientos comúnmente denominados precarios o informales. Se utilizan diferentes nombres y definiciones que incluyen asentamientos informales, precarios, irregulares o espontáneos, barrios marginales, favelas, kampungs, bidonvilles y tugurios, entre otros. Esto genera cierta

confusión para abordar la problemática, ya que todas esas expresiones, aunque en algunos contextos significan lo mismo, en otros presentan diferencias importantes (Morales y Bernal, 2020).

En Latinoamérica, el debate sobre los asentamientos precarios, la informalidad, el acceso a suelo urbano y la vivienda tiene más de medio siglo y aun no se llega a un consenso. En la región SICA, el Glosario Terminológico Anotado sobre Asentamientos Informales y Gestión del Riesgo para Centroamérica y República Dominicana (SICA, 2023) hace referencia a los asentamientos informales señalando, que es necesario armonizar la terminología alrededor de estos para lograr una precisión conceptual y mejorar la comunicación sobre este tema, así como para generar acuerdos y políticas regionales de integración regional. Desde el punto de vista práctico, define a los asentamientos informales como:

Los asentamientos informales son áreas residenciales en las cuales:

- 1. Los habitantes no ostentan derecho de tenencia sobre las tierras o viviendas en las que habitan, bajo las modalidades que van desde la ocupación ilegal de una vivienda hasta el alquiler informal;*
- 2. Los barrios suelen carecer de servicios básicos e infraestructura urbana y*
- 3. Las viviendas podrían no cumplir con las regulaciones edilicias y de planificación y suelen estar ubicadas geográfica y ambientalmente en áreas peligrosas.*

Además, los asentamientos informales pueden ser una manera de especulación inmobiliaria a todos los niveles de ingresos de los residentes, tanto ricos como pobres. Los barrios marginales son los asentamientos informales más necesitados y excluidos, y se caracterizan por la pobreza y las grandes aglomeraciones de viviendas en mal estado, ubicadas, por lo general, en las tierras más peligrosas.

Además de la inestabilidad del derecho de tenencia, los habitantes de los barrios no disponen de infraestructura ni de servicios básicos, espacio público, las áreas verdes y están expuestos de manera constante al desalojo, las enfermedades y la violencia (ONU-Habitat, 2015 en SICA, et. al., 2023).

A nivel de países de Centroamérica y República Dominicana, se observan diferencias también en la conceptualización y terminología alrededor de los asentamientos que articulan características de precariedad y/o informalidad y que, en algunos casos, han dado paso a la elaboración de instrumentos o políticas de atención con objetivos y metas diferenciadas.

En **Guatemala**, por ejemplo, la Ley de *Vivienda* 2012 hace referencia al concepto de asentamientos precarios en el país como *“el conjunto de familias en condiciones de pobreza y pobreza extrema que habitan en áreas con deficiencias en vivienda, servicios, equipamiento y que se encuentran asentados en terrenos no aptos”*. Asimismo, para dar atención a la problemática ha generado la *“Política para el mejoramiento integral de Barrios. Hacia la transformación de asentamientos precarios a barrios consolidados y de viviendas dignas, seguras y saludables 2017 – 2032”*, en la cual se reconoce que no existe información a nivel nacional sobre los asentamientos precarios ni se cuenta con una caracterización general que permita la comprensión de su realidad y dinámicas, de manera diferenciada por ciudades y regiones del país.

Otro ejemplo se observa en **El Salvador** donde los asentamientos precarios urbanos (APU) se definen como *“aglomeraciones espaciales de viviendas que presentan condiciones de precariedad en términos de sus materiales estructurales o en relación con los servicios urbanos básicos a los que acceden”* (FUNDASAL y PNUD, 2009). Para dar atención a ellos, se implementó en 2010, el *“Programa de Mejoramiento Integral de Asentamientos Precarios Urbanos”* cuyo objetivo era mejorar la calidad de vida de las familias que viven en extrema pobreza dentro de los AUP, facilitar su inclusión social a través de la provisión de infraestructura física, fortalecimiento del tejido social y la oportunidad de inserción laboral. Con intervenciones en 25 municipios a nivel nacional, se logró intervenir 30 de los 2,508 asentamientos urbanos precarios existentes, que beneficio a 2,500 familias directamente y a más de 180 mil habitantes impactados indirectamente (UHPH, s.f.; COAMSS y OPAMSS, 2016).

Así como la conceptualización alrededor de los asentamientos precarios o informales es diferenciada por país, la información y estadística disponible también presentan diferencias importantes. En la mayoría de los países no existe información censal oficial y actualizada o que se genere periódicamente, que dé cuenta de la población que habita en hogares en asentamientos urbanos informales y precarios en cada país. De ahí la relevancia de contar con un inventario automatizado de asentamientos precarios que sirva tanto para proveer de información sobre los asentamientos precarios en la región, como para avanzar en la ruta crítica a seguir para actualizar información sobre ellos en el menor tiempo posible, considerando que se trata de fenómenos de rápido crecimiento con población mayoritariamente migrante (ONU-Habitat, 2023).

Los resultados de *“Laboratorios de Vivienda (LAVs): Asentamientos precarios y vivienda social: impactos del Covid – 19 y respuestas”* realizados por la “Plataforma de Prácticas del Hábitat Urbano (UHPH por sus siglas en inglés)” en 2020, señalan que en los países de América

Central existe un importante déficit habitacional que contribuye a la formación de asentamientos informales, los cuales albergan aproximadamente al 29% de la población urbana, pero que en el caso de Guatemala y Nicaragua llegan a 39% y 45%, respectivamente. Estos asentamientos tienden a localizarse en zonas de riesgo a inundaciones, deslizamientos y terremotos, al grado que se estima que 3 de cada 10 vivienda se encuentran en zonas de alto riesgo y de los 11.3 millones de hogares estimados en 2009, el 37% tenía algún tipo de déficit cualitativo. La demanda por vivienda de calidad aumenta significativamente porque se estima que 290,00 hogares se constituyen anualmente.

De acuerdo con SISCA (2020), la proporción de la población urbana que hasta 2017, vivía en barrios marginales, asentamientos informales o viviendas inadecuadas, fluctuaba entre el 5.5 % identificado para Costa Rica considerado el país con el menor porcentaje de población viviendo en este tipo de asentamientos, hasta 45.5 % estimado en Nicaragua, cuyo porcentaje supera al promedio de la región SICA y de América Latina y El Caribe en general.

País	Porcentaje (%)
NIC	45.5%
GUA	38.7%
ESA	28.9%
HON	27.5%
PAN	25.8%
RD	12.1%
BEL	10.8%
CR	5.5%
Población urbana SICA (% promedio)	24.4%
Población urbana ALC (% promedio)	23.9%

Fuente: SISCA (2020 en UHPH, et al, 2020).
Nota: Los datos para CR, ESA, GUA, HON, PAN y RD corresponden al año 2017, para NIC el dato más reciente corresponde al 2014.

ONU-Habitat y otros autores, hacen referencia, en diferentes investigaciones y documentos, tanto a los asentamientos informales como a los asentamientos precarios, evidenciando matices enmarcados entre los fenómenos de desequilibrio, desigualdad territorial y socioeconómica, principalmente.

ASENTAMIENTOS INFORMALES	ASENTAMIENTOS PRECARIOS
<i>“Espacio donde los habitantes se caracterizan por tener vivienda y servicios básicos inadecuados, estar en una condición de hacinamiento crítico, estado precario de la vivienda (en relación con su estructura física y a su entorno), ausencia de algunos de los servicios públicos e ilegalidad de la tenencia de la tierra” (UN-Habitat, 2003).</i>	<i>“Conjunto de viviendas en situación de precariedad, que están agrupadas geográficamente en áreas urbanas, que presentan carencia del total o parte de los servicios básicos (abastecimiento de agua y/o desagüe), problemas de materialidad (pared, piso, techo), tipología de vivienda irrecuperable”, (SENAVITAT, 2011) (Acevedo et al., 2021: pág. 170)</i>
<i>“Son áreas urbanas que se han desarrollado sin cumplir con las normas y regulaciones urbanas, y que a menudo carecen de servicios básicos como agua potable, saneamiento y electricidad” (SICLARI, 2022: pág. 90).</i>	<i>“Se caracterizan por presentar un alto grado de vulnerabilidad ante situaciones de riesgo, tales como desastres naturales, conflictos armados, violencia, entre otros” (Habitat, 2023)</i>

El trabajo más reciente de ONU-Habitat (2023) realizado para la región SICA, basado en investigación documental; comparativas entre el concepto de asentamiento informal y asentamiento precario de instituciones como Naciones Unidas, Alianza de las Ciudades (Cities Alliance), Lincoln Institute of Land Policy y Colombia; y, entrevistas con actores clave de la región, derivó en la siguiente definición de asentamiento precario:

“Un asentamiento precario es cualquier asentamiento humano, urbano o periurbano cuyas características básicas de desarrollo, físicas, legales, ambientales y/o sociales ponen en peligro la integridad y la seguridad de las personas que la habitan. Dentro de sus principales características a observar se encuentran las viviendas ubicadas en zonas expuestas a riesgos ambientales y humanos; hogares contruidos con bajos índices de habitabilidad elaborados con materiales efímeros o inadecuados y con niveles de densidad muy altos o de hacinamiento críticos; viviendas con una cobertura de servicios básicos limitada, informal o inexistente; con una alta desconexión a las centralidades urbanas, bajo acceso a oportunidades y mínima movilidad social” (ONU-Habitat, 2023)

Bajo este contexto y al no haber un consenso en la conceptualización sobre asentamientos precarios e informales en la región, el IAAP distingue de los términos “asentamientos informales” y “asentamientos precarios” las características funcionales que resultan clave y posibles de identificar, de forma automatizada, mediante herramientas tecnológicas e imágenes satelitales de alta resolución. Aspectos como la ocupación ilegal, la titularidad de la tenencia de la tierra, y la aplicación de las normas de construcción a los que refiere el concepto de informales, no son posibles de identificar con las técnicas utilizadas por el IAAP. Sin embargo, si lo son, las viviendas construidas principalmente con materiales efímeros o inadecuados, que son características de los asentamientos precarios. Volviendo a la conceptualización de asentamiento informal, se consideran, además, los aspectos de acceso limitado o inexistente a servicios básicos como agua potable, electricidad o drenaje, materiales de construcción de baja calidad y ubicación en zonas de riesgo, como riberas o pendientes pronunciadas. De los asentamientos precarios que amplían este marco, se considera también, la falta de planificación, las condiciones habitacionales degradadas y contextos de alta vulnerabilidad social y ambiental, que pueden estar presentes incluso en áreas formalmente reconocidas.



3.RUTA CRÍTICA PARA LA CONSOLIDACIÓN DEL IAAP




Figura 1. Ruta de trabajo para la identificación automatizada de asentamientos precarios en Centroamérica y República Dominicana. Fuente: ONU-Habitat, 2024.

La consolidación del IAAP fue posible a través de una metodología que combina un enfoque colaborativo y participativo que integró información sobre asentamientos precarios conocidos provista por funcionarios locales de las ciudades analizadas, con el uso de tecnologías avanzadas de inteligencia artificial y sistemas de información geográfica para la identificación de nuevos polígonos de asentamientos precarios. Como esperado, el resultado principal, fue la generación del mapa y base de asentamientos precarios para la región de Centroamérica y República Dominicana, pero transversalmente resultó también y conforme lo que se describe en la Figura 1, en la definición de [UNAIPS Methodology](#) que es una ruta crítica de 5 etapas clave, utilizada para la generación de información sobre asentamientos precarios en la región SICA, misma que se deja como punto de partida para la actualización de información en años posteriores, así como para promover su escalabilidad hacia otras regiones.

La combinación del análisis y trabajo técnico con procesos participativos en diferentes momentos del proceso hicieron posible la colaboración efectiva con funcionarios gubernamentales y expertos locales en materia de planificación urbana y asentamientos precarios, así como la retroalimentación constante que garantiza la obtención de resultados contextualizados a las particularidades de cada ciudad.

3.1. ETAPA 1: CONSIDERACIONES PRELIMINARES

El paso inicial en [UNAIPS Methodology](#) está orientado a establecer una base operativa sólida que guíe el análisis posterior. Este bloque comprende la definición de las ciudades objetivo, la identificación de indicadores funcionales acorde a la conceptualización de asentamientos precarios y la obtención de una muestra representativa de asentamientos precarios (AP) conocidos en las ciudades de estudio. Además de asegurar contar con los elementos de base que posibilitaran el análisis, la fase preliminar busca orientar las acciones de forma que se alineen con las características particulares de cada contexto urbano, lo cual, contribuye a la precisión del inventario.

3.1.1. DEFINICIÓN DE LAS CIUDADES OBJETIVO

La selección de ciudades se basó en su representatividad dentro de la región SICA, considerando tanto su relevancia en la problemática de asentamientos precarios como su disposición para participar en procesos de mapeo y validación colaborativa. Las ciudades seleccionadas fueron Belice y Belmopán (Belice), San José (Costa Rica), San Salvador (El Salvador), Guatemala (Guatemala), Tegucigalpa (Honduras), Managua (Nicaragua), Panamá (Panamá) y Santo Domingo (República Dominicana). Estas urbes presentan desafíos comunes relacionados con alta concentración de población, urbanización acelerada y la falta de servicios básicos, lo que justifica su inclusión en el estudio.




Figura 2. Esquema gráfico de la selección de ciudades objetivo.
Fuente: ONU-Habitat, 2024.

3.1.2. IDENTIFICACIÓN DE INDICADORES FUNCIONALES

Con la definición de ciudades y de las características comunes de los asentamientos precarios, identificadas a partir del análisis conceptual de asentamientos informales y precarios, se determinaron los indicadores con mayores posibilidades de ser identificados de forma automatizada:

- **Construcciones con materiales de baja calidad** como materiales de desecho, lámina, madera, cartón, triplay, entre otros, que generalmente se usan en las viviendas típicas de los asentamientos precarios (Arista, 2006). La presencia de materiales de lámina en las viviendas precarias es un indicador clave que se tomó en cuenta debido a su importancia significativa en la caracterización remota de estos asentamientos. La lámina es un material característico en muchas viviendas precarias, lo que permite su detección mediante algoritmos ejecutados en imágenes de satélite. Esto se debe a que la lámina presenta una firma espectral única que puede ser distinguida de otros materiales, lo que facilita la identificación y discriminación de estos.
- **Ausencia de servicios básicos** (agua potable, alcantarillado, electricidad) **desde el análisis de la organización espacial.** La distribución y organización espacial de los asentamientos precarios es otro de los aspectos considerados en su caracterización remota. Estos asentamientos

suelen presentar una organización espacial heterogénea y no planificada, caracterizada por la improvisación, la adaptación a las condiciones existentes del terreno y la supresión de la vegetación. La falta de planificación y regulación en la ocupación del suelo y la construcción de viviendas precarias da lugar a una distribución irregular y desordenada de las estructuras.

- **Ubicación en áreas de riesgo naturales y ambientales,** como barrancos, zonas inundables, áreas de deslizamiento o erosión preexistentes, constituyó un aspecto fundamental para identificar zonas vulnerables y de difícil acceso donde podrían existir asentamientos precarios. Esto permitió enfocar los esfuerzos de identificación remota en las zonas de estudio, optimizando así los recursos y maximizando la eficacia en la detección de asentamientos precarios.

La determinación de estos indicadores se dio como resultado de talleres participativos, revisión bibliográfica y documental e intercambio con expertos, que permitió alinear los criterios metodológicos con los objetivos del IAAP. A partir de ellos, se realizó el proceso de programación y entrenamiento.

Además, se definieron indicadores complementarios en el proceso de análisis de resultados. El objetivo de estos indicadores sería posibilitar la validación y discriminación precisa de los resultados generados por *UNAIPS Methodology*, para contribuir a una mayor confiabilidad y exactitud en los resultados finales. Los indicadores seleccionados fueron:

- **Pendiente del terreno:** La pendiente es uno de los factores que controla los procesos gravitacionales de remociones en masa. Por ello, es necesario establecer cuáles son los valores de pendiente a partir de los cuales se activan dichos procesos. Estos umbrales varían según la naturaleza de los materiales (DESI, 2022), sin embargo, para este análisis, se estableció como parámetro de referencia, la inclinación igual o superior al 35%, que es considerado como zona de riesgo, debido a la mayor probabilidad de deslizamientos de tierra, erosión, dificultades para la construcción y el acceso, y mayor vulnerabilidad a desastres naturales.

Mediante los modelos digitales de elevación (MDE), se generaron rangos de pendiente para cada una de las ciudades, lo que permitió discriminar y seleccionar aquellos polígonos ubicados en zonas con pendientes inferiores al 35%.

- **Temperatura de la superficie terrestre:** Para estimar la temperatura de la superficie terrestre, se extrajo la información de las bandas térmicas de las imágenes de satélite, que luego se procesaron mediante un software cartográfico especializado. Este proceso permitió convertir los valores de radiancia espectral en temperatura de la superficie terrestre en grados Celsius, lo que facilitó el uso y análisis de los datos para la investigación.

Además del análisis documental en línea, se realizó una estimación consensuada de las temperaturas que oscilan para materiales de construcción de techos relacionados principalmente con lámina, lo que permitió obtener una visión más completa y precisa de las temperaturas que se pueden alcanzar en estos materiales. Las temperaturas superficiales del total de los materiales se derivan del efecto combinado de la composición, textura, color y forma, pero el color resulta la variable de mayor impacto en el comportamiento térmico (ALCHAPAR, 2015).

Los registros determinantes establecidos oscilaron entre 56°C y 64°C, los cuales reflejan la densidad de materiales constructivos característicos de los asentamientos precarios, proporcionando una referencia importante para entender las condiciones térmicas en estos tipos de asentamientos.

- **Superficie mínima:** Se estableció un criterio de selección para polígonos con un área superior a 0.1 hectáreas, con el objetivo de garantizar la relevancia estadística de los resultados. Este criterio se combinó con el análisis visual, permitiendo una filtración y priorización efectiva de las áreas de interés en el inventario, lo que optimizó la identificación y el estudio de las zonas más relevantes.

3.1.3. DEFINICIÓN DE MUESTRA DE ASENTAMIENTOS PRECARIOS CONOCIDOS

Para el proceso de *UNAIPS Methodology* se creó una base de datos inicial con una muestra representativa de asentamientos precarios en las ciudades de análisis. La muestra fue esencial para el entrenamiento de los algoritmos empleados en esta metodología, ya que permitió identificar los elementos característicos de los asentamientos precarios en cada ciudad y asegurar que la detección automatizada reflejara las características únicas de cada contexto urbano. Además, la muestra fue crucial para validar la precisión de los resultados obtenidos y confirmar si estos correspondían efectivamente con la ubicación de las zonas precarias en cada área de estudio.

La información y muestra de asentamientos precarios conocidos se consolidó mediante diferentes fuentes: bibliográfica y documental; análisis de datos e información pública; solicitud de información a instancias del gobierno local; recorridos de campo y talleres con actores clave de gobierno en cada ciudad. Estas actividades se realizaron en estrecha colaboración con funcionarios de los sectores gubernamentales responsables de la planificación y gestión de asentamientos urbanos en cada una de las ciudades objetivo.

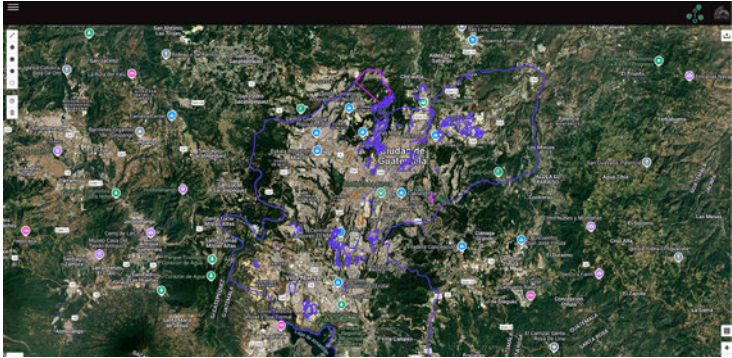
En el caso de Guatemala, Managua, Santo Domingo y Panamá se llevaron a cabo cuatro talleres virtuales, uno por ciudad, en febrero de 2024, en conjunto con la unidad de Tecnología de Innovación de las Naciones Unidas para las ciudades (UNITAC). A través de estos talleres fue posible intercambiar con funcionarios locales de las diferentes ciudades, representantes de seis sectores gubernamentales especializados en planeación urbana, vivienda y asentamientos informales, los cuales, compartieron experiencias, conocimientos y mejores prácticas en materia de mapeo y caracterización de asentamientos precarios en cada una de sus ciudades.

Ciudad de Guatemala

¡Bienvenidos a nuestro Taller de Mapeo Colaborativo! Esta sesión organizada conjuntamente por UN-Habitat y UNITAC (United Nation Innovation Technology Accelerator for Cities), tiene como objetivo reunir a representantes municipales para identificar y mapear colectivamente los asentamientos informales en sus respectivas ciudades utilizando esta herramienta basada en imágenes aéreas avanzadas.

by Mike Hathorn

Open

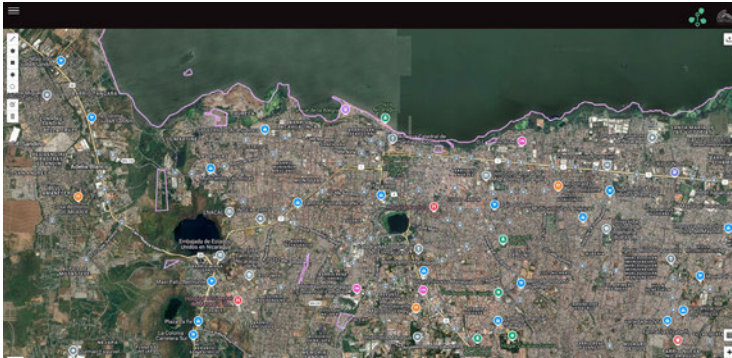


Managua

¡Bienvenidos a nuestro Taller de Mapeo Colaborativo! Esta sesión organizada conjuntamente por UN-Habitat y UNITAC (United Nation Innovation Technology Accelerator for Cities), tiene como objetivo reunir a representantes municipales para identificar y mapear colectivamente los asentamientos informales en sus respectivas ciudades utilizando esta herramienta basada en imágenes aéreas avanzadas.

by Mike Hathorn

Open

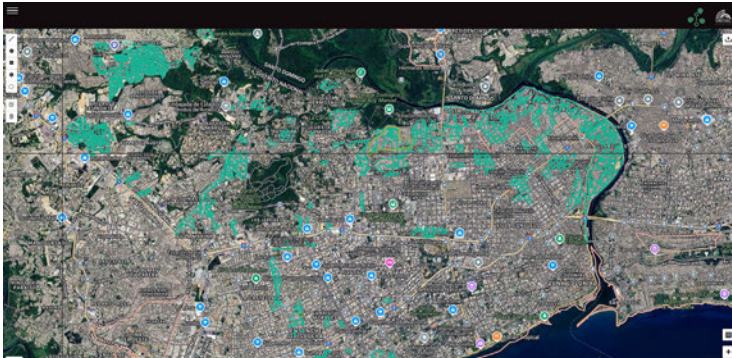


Santo Domingo

¡Bienvenidos a nuestro Taller de Mapeo Colaborativo! Esta sesión organizada conjuntamente por UN-Habitat y UNITAC (United Nation Innovation Technology Accelerator for Cities), tiene como objetivo reunir a representantes municipales para identificar y mapear colectivamente los asentamientos informales en sus respectivas ciudades utilizando esta herramienta basada en imágenes aéreas avanzadas.

by Mike Hathorn

Open



Panama City

¡Bienvenidos a nuestro Taller de Mapeo Colaborativo! Esta sesión organizada conjuntamente por UN-Habitat y UNITAC (United Nation Innovation Technology Accelerator for Cities), tiene como objetivo reunir a representantes municipales para identificar y mapear colectivamente los asentamientos informales en sus respectivas ciudades utilizando esta herramienta basada en imágenes aéreas avanzadas.

by Mike Hathorn

Open

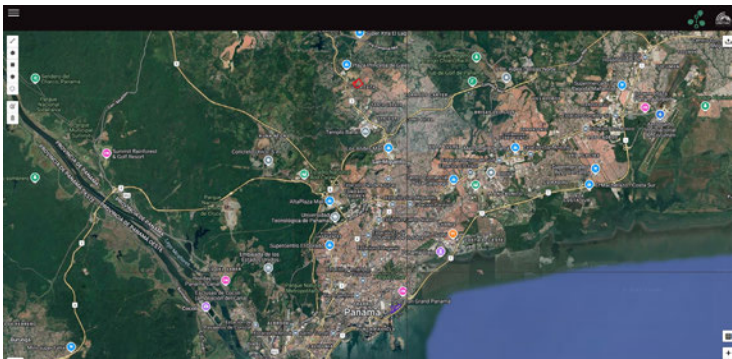


Figura 3. Participación colaborativa con el equipo UNITAC.
Fuente: ONU-Habitat, 2024.

Como resultado se conformó una muestra de polígonos representativos de asentamientos precarios para las cuatro ciudades. Esta información se obtuvo mediante la combinación de datos vectoriales compartidos por las ciudades y la digitalización realizada durante los talleres. Este proceso no solo fortaleció significativamente las capacidades técnicas del equipo y la articulación, sino que también sentó las bases para abordar de manera integral el desafío que representan estos asentamientos.

Los recorridos de campo se llevaron a cabo en Belice y Nicaragua y se dieron como resultado de la limitada información a la que se podía acceder, a través de fuentes secundarias. En específico se realizaron recorridos en las ciudades de Belice y Belmopán con acompañamiento de funcionarios de la unidad y gestión de proyectos del Ministerio de Infraestructura, Desarrollo y Vivienda (MIDH) y del ayuntamiento de Ciudad Belice; y en Managua con apoyo del Instituto de Vivienda y Urbanismo de Nicaragua. A través de estos recorridos, se pudo recolectar información de 9 polígonos de asentamientos precarios en la ciudad de Managua y de 154 polígonos para las ciudades de Belice y Belmopán, que se sumaron a otros identificados a través de fuentes secundarias.



Figura 4. Asentamientos precarios visitados en Belice y Belmopán en Belice y Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.

En el caso de El Salvador, la Oficina de Planificación del Área Metropolitana de San Salvador (OPAMSS) que cuenta con una base de datos e información bastante nutrida sobre asentamientos precarios del Área Metropolitana de San Salvador, proporcionó 301 polígonos de asentamientos precarios conocidos. En el caso de Tegucigalpa, Honduras la muestra se conformó por un total de 51 polígonos de asentamientos precarios, recopilados por medio de fuentes secundarias y retroalimentación con funcionarios locales. Finalmente, para San José, Costa Rica, la información fue proporcionada, en formato vectorial, por la Municipalidad de San José. En total facilitó 284 polígonos de asentamientos precarios conocidos.

Destaca mencionar que, para todas las ciudades, la información obtenida, fue revisada, analizada y/o depurada, para consolidar una muestra inicial sólida, a partir de la cual, se realizó la programación del algoritmo para cada ciudad. La depuración consistió principalmente en el ajuste en la delimitación de los polígonos de asentamientos precarios conocidos, así como en la supresión de zonas de vegetación evidente, que pudieran generar ruido al momento del entrenamiento. En algunos casos, la depuración se realizó también a partir del contraste con parámetros de ubicación en zonas no servidas o con pendientes pronunciadas, traza urbana irregular, red vial indefinida y/o con pisos de tierra, entre otros aspectos.

3.2. ETAPA 2: MODELADO (MACHINE LEARNING)

El segundo paso de *UNAIPS Methodology* se centra en el desarrollo y aplicación de herramientas de análisis espacial basadas en aprendizaje automático, complementadas con la gestión eficiente de datos geoespaciales. Este bloque incluye desde la adquisición y tratamiento de imágenes satelitales hasta la programación, entrenamiento y personalización de algoritmos específicos para las ciudades objetivo.

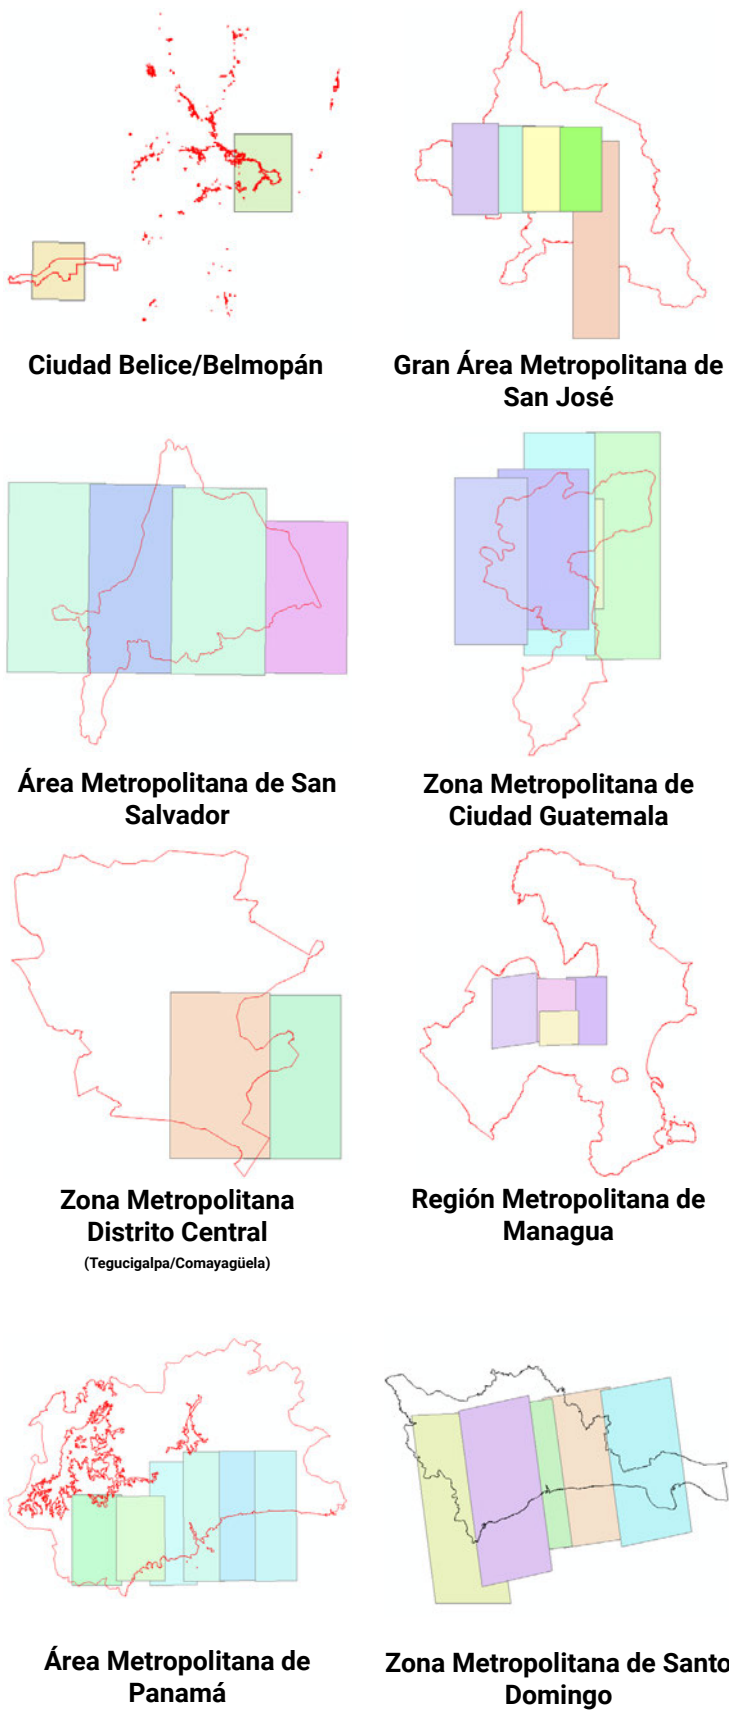


Figura 5. Cobertura de imágenes de satélite WorldView-2 por ciudad. Fuente: ONU-Habitat, 2024.

3.2.1. ADQUISICIÓN Y TRATAMIENTO DE IMÁGENES SATELITALES

Las imágenes de satélite de alta resolución en conjunto con la muestra de asentamientos precarios posibilitaron la programación, entrenamiento y detección automatizada de asentamientos precarios en cada una de las ciudades analizadas. Se utilizaron, imágenes de satélite WorldView-2 de los años 2023 y 2024, principalmente, mismas que fueron facilitadas por el equipo UNITAC, con quien se estableció una alianza estratégica de colaboración para el desarrollo del IAAP. Sin embargo, la falta de cobertura completa de las imágenes satelitales, limitó la obtención de resultados para toda la superficie de las ciudades analizadas (figura 5). No obstante, la calidad y temporalidad de las imágenes en la cobertura disponible fueron óptimas, lo que permitió obtener buenos resultados a lo largo del proceso.

En el caso de la ciudad de Tegucigalpa que cuenta con una orografía accidentada, provocando la generación de sombras en algunas partes de las imágenes de satélite World View-2; se determinó usar imágenes Maxar, proporcionadas por GIZ, las cuales, resultaron con mejor calidad y cobertura total de la ciudad, para la programación y modelado. A lo largo del proceso, también se utilizaron imágenes Landsat 9, disponibles a través del servidor del Servicio Geológico de la NASA (USGS, 2024) que, en conjunto con el uso del modelo de elevación digital, posibilitaron contar con información complementaria para identificar patrones térmicos y espectrales en las diferentes ciudades.

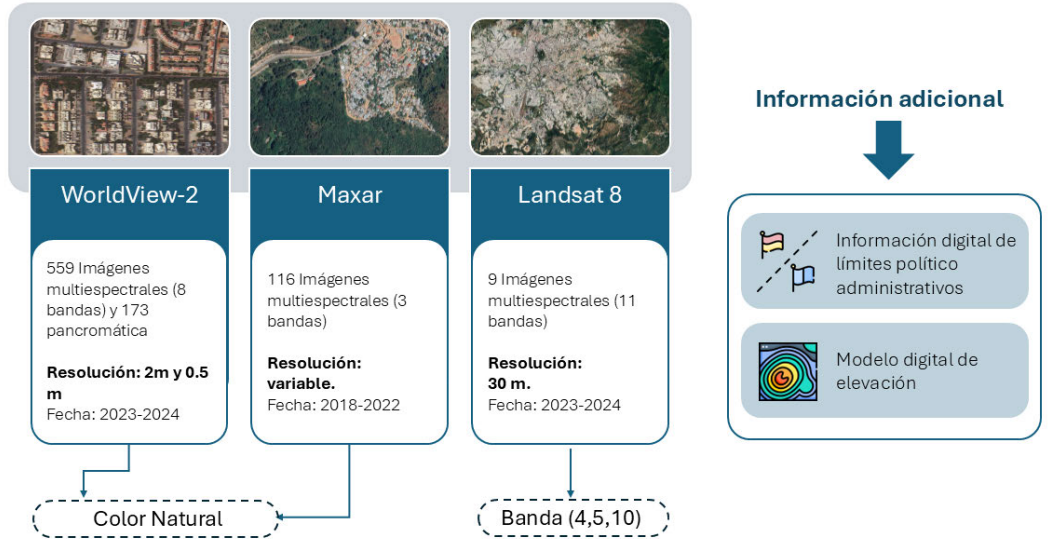


Figura 6. Imágenes de satélite usadas y elementos iniciales para el estudio. Fuente: ONU-Habitat, 2024.

El tratamiento de las más de 500 imágenes utilizadas implicó la generación de mosaicos a través de Pansharpening, que resultó en la creación de imágenes en color de alta resolución, generados a través de la combinación de bandas específicas con imágenes pancromáticas. El objetivo principal de este proceso fue mejorar la calidad de las imágenes para optimizar el entrenamiento y modelado de las ciudades, con el fin de detectar características asociadas con la precariedad de los asentamientos, manteniendo una resolución óptima que permitiera obtener resultados más precisos.

3.2.2. PROGRAMACIÓN Y DESARROLLO

El uso de algoritmos avanzados ha sido fundamental para el progreso en el mapeo automatizado de asentamientos precarios en Centroamérica y República Dominicana. Un antecedente de algoritmos similares generados en la región, que además fungió como punto de partida en este proceso, fue el algoritmo MAIIA, desarrollado por el BID. Este algoritmo proporcionó una herramienta de código abierto altamente efectiva para identificar asentamientos informales en América Latina mediante el análisis de imágenes satelitales. MAIIA no solo demostró ser una solución innovadora, sino que también proporcionó las bases conceptuales y técnicas necesarias para el desarrollo en *UNAIPS Methodology*, una herramienta adaptada a las especificidades locales.

UNAIPS Methodology representa una evolución significativa del enfoque inicial de MAIIA, perfeccionando su metodología para responder a las complejidades urbanas de cada ciudad en análisis. Este avance no habría sido posible sin el aprendizaje adquirido a través de MAIIA, que sentó las bases para la conceptualización y diseño de un modelo más flexible y específico.

El desarrollo de *UNAIPS Methodology* implicó:

- El desarrolló de un Pipeline que cubre todo el proceso, desde la manipulación de imágenes y de los datos a través de VSCode hasta la detección utilizando un modelo entrenado. Este pipeline también incluye la integración de indicadores clave, como la temperatura superficial y la pendiente del terreno, para enriquecer el análisis.
- La implementación de un enfoque experimental iterativo para mejorar el modelo, realizando numerosas pruebas de configuración y ajuste fino. Este proceso implicó explorar y optimizar múltiples hiperparámetros y arquitecturas, lo que requirió un análisis detallado de los resultados obtenidos en cada iteración para alcanzar un equilibrio óptimo entre precisión y eficiencia.
- La generación de archivos interactivos y comprensibles en Jupyter Notebooks, diseñados para documentar y ejecutar cada paso del pipeline de manera clara y estructurada. Estos notebooks permiten una fácil reproducción del proceso y simplifican la comprensión de cada etapa, desde la manipulación de datos hasta la detección y análisis final.
- La optimización del proceso mediante diversas pruebas para identificar las limitaciones de la infraestructura utilizada en la manipulación de imágenes satelitales. Esto permitió encontrar un equilibrio óptimo entre la cantidad de imágenes empleadas para el entrenamiento del modelo y aquellas utilizadas para la detección, maximizando el rendimiento dentro de las capacidades del sistema.

Esta metodología no solo incrementa la precisión y relevancia de los resultados, sino que también demuestra cómo la experiencia con MAIIA permitió mejorar y adaptar el modelo a las necesidades locales. Al integrar herramientas innovadoras como *UNAIPS Methodology*, cuyos detalles técnicos se encuentran en el anexo 1 , ONU-Habitat reafirma su compromiso con soluciones tecnológicas avanzadas para la planificación urbana y la gestión estratégica de asentamientos precarios, asegurando que las decisiones se basen en datos confiables y específicos al contexto.

3.2.3. ENTRENAMIENTO DEL ALGORITMO

El entrenamiento de los algoritmos usados en *UNAIPS Methodology* se realizaron de manera individual para cada ciudad, usando la muestra de asentamientos precarios previamente definida como se describió en el paso 3.1.3. Este enfoque personalizado evitó problemas de generalización que surgen al aplicar un modelo único a contextos urbanos diversos.

El proceso de entrenamiento incluyó:

- La creación de un archivo geojson de las zonas de interés que incluye la ubicación de la información de los asentamientos precarios conocidos (muestra inicial).
- Implementación de técnicas de segmentación semántica y transformaciones aleatorias de imágenes utilizando Raster Vision con el objetivo de preparar la información de manera adecuada para el entrenamiento. Estas augmentaciones, aplicadas de forma controlada, contribuyeron a aumentar la diversidad del conjunto de datos, permitiendo obtener un modelo más robusto.



Figura 7. Ejemplo de áreas de interés para San José, Costa Rica.
Fuente: ONU-Habitat, 2024.

- Ajustes en la cantidad de imágenes procesadas por iteración para adaptarse a la disponibilidad desigual de datos entre las distintas ciudades. Este ajuste permitió garantizar un procesamiento equilibrado, sin exceder la capacidad de la infraestructura utilizada para el entrenamiento, optimizando así el uso de los recursos disponibles.
- Fortalecimiento del modelo entrenado empleando dos tipos de polígonos: áreas y techos. Esta estrategia permitió al modelo aprender a identificar y segmentar de manera más precisa diferentes características, mejorando así su robustez y precisión.
- Validación cruzada para evaluar la precisión del modelo y ajustar los pesos asociados a los indicadores.

3.2.4. APLICACIÓN DEL MODELO Y GENERACIÓN DE RESULTADOS INICIALES

Una vez entrenado el modelo para cada ciudad, se llevó a cabo la detección automatizada de asentamientos precarios mediante análisis espectral de las imágenes de satélite, una técnica que permite realizar un estudio detallado de la reflectancia emitida por los cuerpos en la superficie terrestre. Este método de análisis espectral extrae información valiosa sobre la composición y propiedades de los objetos observados en el territorio, lo que resulta fundamental para identificar áreas de interés.

La principal ventaja de este enfoque es su capacidad para estudiar áreas de extensa superficie de manera eficiente y no invasiva, lo que lo convierte en una herramienta ideal para la identificación de asentamientos precarios en contextos urbanos complejos. Dos puntos importantes que se destacan durante este procesamiento son:

- **Tiempo de procesamiento:** El tiempo promedio de procesamiento por imagen satelital fue de 15 y 20 minutos, considerando que cada ciudad disponía de aproximadamente 24 imágenes después de la optimización. Sin embargo, este tiempo de procesamiento puede variar en función de los recursos tecnológicos y capacidad de memoria y almacenamiento con que se cuente.
- **Generación de resultados:** La generación de resultados preliminares se generó archivos en formato GeoJSON, listos para su integración y gestión a través de sistemas de información geográfica (SIG).

Tal como se muestra en la figura a continuación, el entrenamiento específico por ciudad permitió personalizar los parámetros del modelo, atendiendo las diferencias urbanas y topográficas, lo que redujo errores y mejoró la precisión en la identificación de áreas precarias.

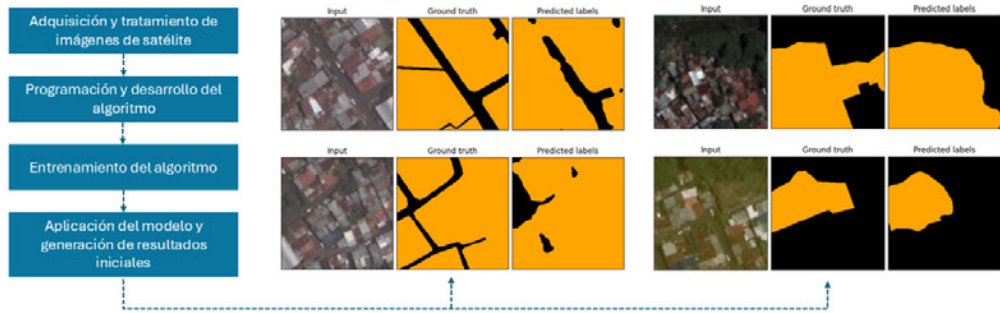


Figura 8. Ejemplos de los resultados preliminares obtenidos posterior al entrenamiento, dentro del software VS Code.
Fuente: ONU-Habitat, 2024.

3.3. ETAPA 3: IDENTIFICACIÓN Y CARACTERIZACIÓN DE ASENTAMIENTOS PRECARIOS (GESTIÓN)

El tercer paso de *UNAIPS Methodology* se centra en la detección y gestión de datos resultantes del análisis automatizado, a través de un proceso iterativo que integra la validación y el refinamiento de los resultados. Este paso es importante considerar para garantizar que los asentamientos identificados cumplan con los criterios establecidos de precariedad y para validar su relevancia dentro del contexto urbano de cada ciudad.

3.3.1. ANÁLISIS DE RESULTADOS POST-PROCESAMIENTO

Los resultados obtenidos en el análisis inicial fueron depurados mediante sistemas de información geográfica (SIG), aplicando criterios de exclusión y filtros complementarios. Las tareas incluyeron:

- La unión de geometrías (merge) para simplificar la visualización y análisis.
- Descarte de polígonos irrelevantes según criterios preestablecidos, detallados en el apartado de “identificación de indicadores funcionales”. Se detallan a continuación, la funcionalidad y los parámetros establecidos para tres indicadores inicialmente considerados, además de un cuarto indicador adicional: la validación con datos iniciales:
 - **Eliminación de superficie mínima:** se descartaron áreas que no cumplieran con los criterios establecidos, como superficies menores a 0.1 hectáreas, zonas en cuerpos de agua, vegetación sin ocupación humana o áreas industriales.
 - **Indicador de pendiente del terreno:** se conservaron los polígonos con pendientes iguales o superiores al 35%, al considerarse un factor de riesgo y vulnerabilidad asociado a la precariedad.
 - **Indicador de temperatura superficial terrestre:** se filtraron y conservaron las áreas dentro del rango de 56°C a 64°C, que corresponde a temperatura emitida por los materiales de los techos en zonas precarias, captada a través de las imágenes de satélite.
 - **Validación con datos iniciales:** Comparación de los polígonos resultantes a través de la predicción con los polígonos muestra o de entrenamiento.

Los indicadores funcionales no se utilizaron de manera uniforme en las ocho ciudades debido a sus diferencias contextuales (por ejemplo, hay ciudades en terrenos planos donde el análisis de pendiente no tiene lugar) o a características propias de las imágenes (como nubosidad en algunas partes) que limitaron el análisis de indicadores como la temperatura de la superficie, por ejemplo. Esto llevó a que la implementación de los indicadores variara entre cada ciudad. Sin embargo, cada ciudad contó con una validación personalizada acorde a sus características.

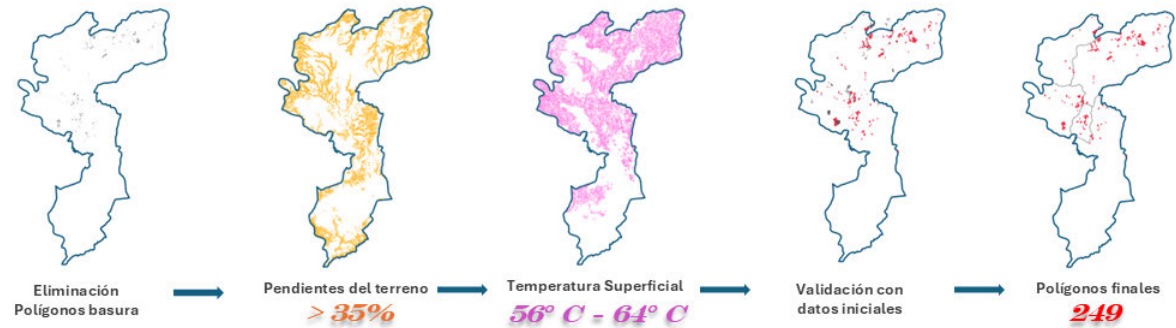


Figura 9. Análisis de resultados post-procesamiento.
Fuente: ONU-Habitat, 2024.

Este análisis refinado permitió reducir los falsos positivos y mejorar la calidad de la base de datos geoespacial. Ejemplo de este proceso que denota el contraste de la información inicial obtenida y la posterior al procesamiento en las ciudades de Managua y Panamá, se muestra en las figuras a continuación.




Figura 10. Ejemplo de los resultados iniciales y los resultados post-procesamiento, para la Región Metropolitana de Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.

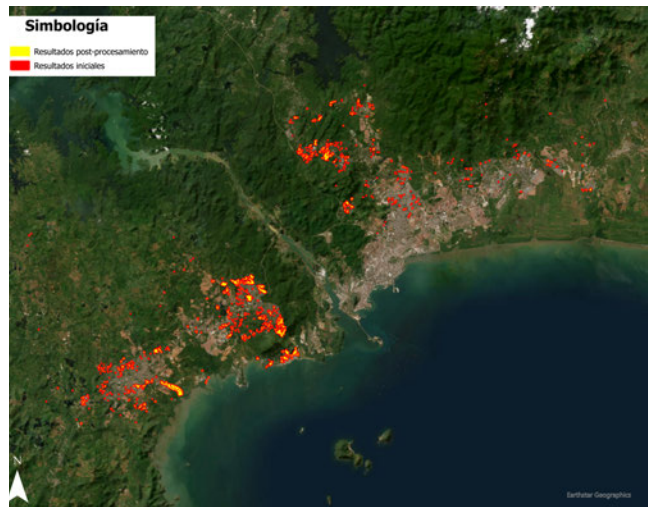


Figura 11. Ejemplo de los resultados iniciales y los resultados post-procesamiento, para el Área Metropolitana de Panamá, Panamá.
Fuente: ONU-Habitat, 2024.

3.3.2. COMPARACIÓN CON DATOS Y LÍNEA BASE

Otro de los ejercicios clave realizados para verificar la precisión de los polígonos resultantes, consistió en la comparación de estos, con la muestra inicial de polígonos conocidos en cada ciudad o con mapas previos y estudios de asentamientos precarios, identificados a través de fuentes secundarias.




Figura 12. Ejemplo de los resultados obtenidos por *UNAIPS Methodology* (en amarillo) y polígonos iniciales de AP (en blanco) para la Zona Metropolitana de Santo Domingo.
Fuente: ONU-Habitat, 2024.

El contraste entre la información inicial y la final obtenida, permitió verificar la adecuada programación y funcionamiento del algoritmo. En la siguiente tabla, se pueden apreciar las comparaciones del número de polígonos de asentamientos precarios iniciales, obtenidos por diversas fuentes para el procesos de *UNAIPS Methodology* en el entrenamiento del algoritmo; y los resultados finales obtenidos, post-procesamiento. También se incluye una aproximación a la superficie total de polígonos de asentamientos precarios identificados en cada ciudad, a través de esta metodología.

PAÍS	CIUDAD	NÚMERO DE POLÍGONOS INICIALES	NÚMERO DE POLÍGONOS AP	SUPERFICIE POLÍGONOS AP (HA)
Belice	Belice y Belmopán	154	169	115.58
Costa Rica	Gran Área Metropolitana de San José	284	260	194.21
El Salvador	Área Metropolitana de San Salvador	301	1,195	715.16
Guatemala	Zona Metropolitana de la Ciudad de Guatemala	434	249	169.20
Honduras	Zona Metropolitana Distrito Central (Tegucigalpa y Comayagüela)	51	312	83.88
Nicaragua	Región Metropolitana de Managua	9	833	320.08
Panamá	Área Metropolitana de Panamá	51	852	910.66
República Dominicana	Zona Metropolitana de Santo Domingo	835	1,765	491.54

Tabla 1. Relación del número de polígonos iniciales y el número de polígonos AP resultado del *UNAIPS Methodology*.
Fuente: ONU-Habitat, 2024.

En ciudades donde existían bases de datos limitadas y conforme se describirá a continuación, los resultados se validaron a través de talleres participativos con expertos locales.

3.3.3. ESTRATEGIA PARTICIPATIVA PARA LA REVISIÓN DE RESULTADOS

Un aspecto esencial en diferentes momentos del proceso fue la incorporación de un enfoque colaborativo, mediante la realización de talleres con funcionarios locales especializados en planificación urbana, vivienda y asentamientos precarios, de algunas de las ciudades analizadas. Estos talleres permitieron:

- Validar y enriquecer los resultados obtenidos.
- Incorporar el conocimiento local para identificar asentamientos que pudieran no haber sido detectados automáticamente.
- Fortalecer las capacidades técnicas de los participantes mediante la capacitación en herramientas geoespaciales y análisis colaborativo.
- Reflexionar sobre los resultados obtenidos y procesos de mejora para la programación y modelado.

Se realizaron dos talleres de trabajo técnico, que combinaron sesiones remotas y presenciales, con dos ciudades muestra: San José, Costa Rica y San Salvador, El Salvador. El objetivo de estos talleres fue realizar la revisión y retroalimentación de la información preliminar obtenida de asentamientos precarios identificados de forma automatizada a través de *UNAIPS Methodology* y, definir parámetros para mejorar y afinar los resultados en el resto de las ciudades. El ejercicio, permitió identificar también, áreas de mejora al modelado y programación del algoritmo. En el taller de San José participaron 4 funcionarios (3 hombres y una mujer) del Área de Vivienda y Asentamientos Humanos de la Municipalidad de San José y en el caso de El Salvador, participaron 16 funcionarios (6 mujeres y 10 hombres) de la OPAMSS y de diferentes distritos del AMSS.

Dentro de los hallazgos de estos talleres, expresados por los participantes, a partir de la información presentada se encuentran: a) la identificación de nuevos polígonos de asentamientos precarios, incluso de los que tienen superficies menores que son característicos de la región; b) la identificación, en zonas no precarias y zonas industriales, de la degradación de materiales y/o el uso de materiales en cocheras o zonas de almacenaje en pisos superiores de la vivienda, que se identifican o relacionan comúnmente con los materiales utilizados en las viviendas de asentamientos precarios y c) la superficie de los polígonos asentamientos precarios generados de forma automatizada no corresponde a la superficie total del asentamiento conforme lo que se observa en la realidad.

Al respecto de este último punto, se reconoce que el algoritmo es limitado en la delimitación de la superficie precisa del asentamiento precario, considerando que lo que analiza y detecta son los elementos esenciales o principales que caracterizan a las viviendas de los asentamientos precarios en la región, dejando de lado algunos otros elementos que forman parte del propio asentamiento. Esto subraya la importancia de realizar la validación final a través de una verificación en campo tanto para mejorar la precisión de los resultados en cuanto a superficie de los asentamientos precarios

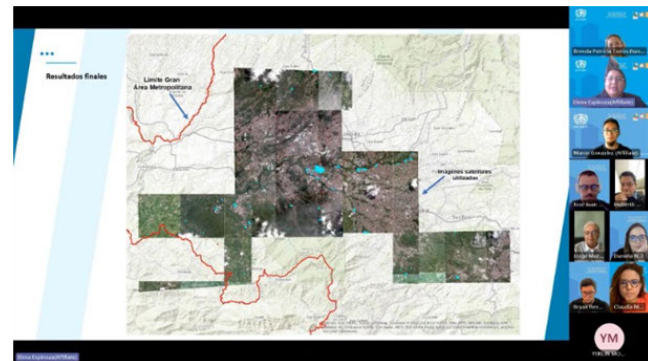


Figura 13. Talleres participativos realizados con la ciudad de San Jose y de San Salvador, a través de sesiones remotas y presenciales. Fuente: ONU-Habitat, 2024.

identificados, como para conocer con mayor exactitud el número de personas que los habitan y recolectar información adicional que permitan realizar una caracterización más completa de estos asentamientos.

3.3.4. CARACTERIZACIÓN INICIAL: APROXIMACIÓN AL NÚMERO DE EDIFICACIONES O VIVIENDAS EN LOS ASENTAMIENTOS PRECARIOS

La caracterización inicial de los asentamientos precarios identificados por *UNAIPS Methodology*, se llevó a cabo a través de la identificación o aproximación al número de techos de edificaciones para cada uno de los polígonos resultantes que, de forma general, podría constituirse como una primera aproximación al número viviendas existentes en cada asentamiento identificado. La identificación de techos se realizó con apoyo de UNITAC, a través de su herramienta *BEAM*.

Como se detalla en el anexo 2 , el algoritmo *BEAM* (Building & Establishment Automated Mapper) es una herramienta que utiliza aprendizaje automático y visión artificial para detectar y mapear edificaciones



en imágenes aéreas que, correspondieron a las mismas que sirvieron de base para el desarrollo de *UNAIPS Methodology*. Asimismo, utiliza técnicas avanzadas de segmentación semántica para analizar imágenes y generar mapas detallados de áreas urbanas, así como para identificar estructuras urbanas dentro de los asentamientos precarios identificados. Su objetivo es apoyar a la caracterización inicial con fines de planificación y gestión de estos asentamientos de manera más eficiente.




Figura 14. Representación de la información de techos identificada por la herramienta BEAM de UNITAC, para polígonos de asentamientos precarios detectados en el Área Metropolitana de San Salvador, El Salvador. Fuente: ONU-Habitat, 2024.

A partir del algoritmo *BEAM*, fue posible el análisis de todos los asentamientos precarios identificados por *UNAIPS Methodology*, así como la obtención del número aproximado de techos en estos polígonos.

3.3.5. GENERACIÓN DEL INVENTARIO PRELIMINAR

A partir del inventario de asentamientos precarios identificados por *UNAIPS Methodology*, revisado y validado previamente; así como con la información de las estructuras de techos identificados en cada uno de ellos, a través de la herramienta *BEAM*, el paso siguiente en el proceso del IAP consistió en la generación de la siguiente información:

- Mapas detallados por ciudad con los polígonos de asentamientos precarios identificados, asociados a una base de datos que contiene información general de asentamiento y la información del número de techos identificados en cada uno de ellos.
- Datos estadísticos sobre la distribución y características de los asentamientos en cada ciudad.

Toda esta información se generó en formato vectorial y ha sido empaquetada en archivos comprimidos para su uso y gestión mediante herramientas SIG, así como a través de Google Earth.

3.4. ETAPA 4: CONSOLIDACIÓN Y SOCIALIZACIÓN DE INVENTARIO AUTOMATIZADO DE ASENTAMIENTOS PRECARIOS (IAAP)

El cuarto paso de la metodología se enfoca en la consolidación y difusión de los resultados del (IAAP) entre las instituciones y actores clave de cada ciudad. Este proceso busca asegurar que los productos generados estén disponibles para los tomadores de decisiones en formatos accesibles, así como que cuenten con información comprensible, útil y aplicable para la planificación urbana y la gestión integral de los asentamientos precarios en cada ciudad.

Como señalado, el inventario consolidado incluye un mapa geoespacial de los asentamientos identificados, acompañado de una base de datos que detalla atributos relevantes como superficie, ubicación y características físicas, así como aproximaciones al número de viviendas en cada asentamiento. Esta información, acompañada de un informe técnico que detalla las etapas metodológicas, los resultados obtenidos y las recomendaciones para su implementación en políticas públicas y estrategias de intervención integral de los asentamientos precarios; esta disponible para los funcionarios de las áreas de vivienda y asentamientos informales de los 8 países de la región, para su conocimiento, archivo y uso.

Además, se plantea, la presentación y socialización de los resultados obtenidos, mediante sesiones específicas con cada ciudad o a través de eventos regionales, a partir de los cuales, se busca cumplir con los siguientes objetivos:

- Presentar los resultados generados, los hallazgos identificados y los retos superados, destacando el papel de la tecnología y la participación colaborativa en el proceso implementado para la consolidación del IAAP.
- Difundir la metodología utilizada con fines de identificación de posibles alianzas para su mejoramiento y/o escalamiento.
- Posicionar la importancia de la revisión en campo, de la información obtenida o de una muestra de los polígonos de asentamientos precarios identificados con fines de validación final de los resultados obtenidos.
- Generar recomendaciones para el abordaje o intervención integral de los asentamientos precarios a través de metodologías participativas como la de Operaciones Urbanas Integrales que es flexible, inclusiva y se adapta a diferentes contextos y situaciones identificadas en este tipo de asentamientos.

3.5. ETAPA 5 (OPCIONAL): VERIFICACIÓN EN CAMPO Y VALIDACIÓN FINAL POR PARTE DE LOS GOBIERNOS LOCALES.

El último paso propuesto en la metodología del IAAP, consiste en la verificación en campo y la validación final de los polígonos de asentamientos precarios identificados, como una actividad recomendada a realizar por parte de los gobiernos locales que deseen profundizar en la precisión de los datos generados. Este paso permitiría corroborar los resultados obtenidos a través del algoritmo y ajustar posibles discrepancias detectadas durante el análisis inicial, brindando a las autoridades locales una base sólida para la toma de decisiones.

Este proceso incluiría la definición de un esquema de muestreo que abarquen polígonos representativos, seleccionados en función de la diversidad geográfica y las características específicas de los asentamientos precarios identificados. Los equipos técnicos locales podrían realizar visitas de campo para confirmar la ubicación y extensión de los polígonos, así como recopilar información adicional sobre las condiciones físicas, sociales y ambientales de los asentamientos. Estas actividades podrían complementarse con observaciones directas y entrevistas a los residentes, proporcionando un contexto más amplio y detallado.

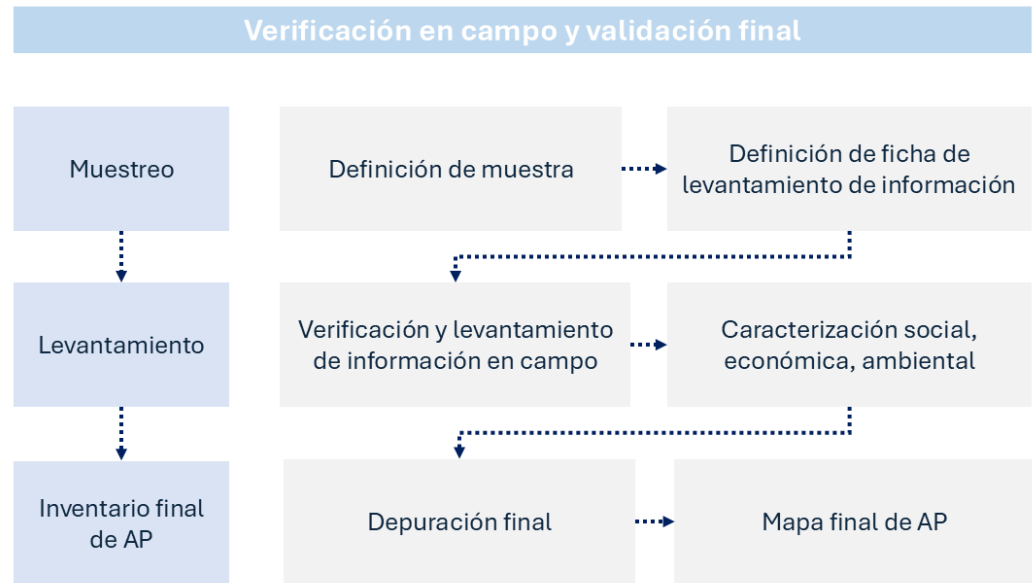


Figura 15. Propuesta de actividades a realizar como parte de la verificación en campo y validación final de los resultados obtenidos como parte del IAAP. Fuente: ONU-Habitat, 2024.

Conforme lo que se propone en esta etapa, los datos obtenidos a través de la verificación en campo, permitiría a los gobiernos locales realizar ajustes en el inventario, como la corrección de la extensión de los polígonos y la adición de información relevante sobre las características de las viviendas y el entorno. Este refinamiento fortalecería la utilidad del inventario al adaptarlo mejor a las realidades locales. Aunque no es obligatorio este paso, es altamente recomendable para maximizar la precisión y aplicabilidad de los resultados. La implementación de estas actividades dependerá de los recursos disponibles, las capacidades técnicas y las prioridades locales, pero su ejecución puede ofrecer un producto final más robusto y contextualizado para facilitar la planificación urbana y la intervención integral de los asentamientos precarios en las diferentes ciudades analizadas.

Esta metodología, que articula el análisis tecnológico y la colaboración comunitaria, refuerza la alineación del IAAP con la Nueva Agenda Urbana y los ODS. Al priorizar el uso de herramientas innovadoras como el aprendizaje automático y la inteligencia artificial, se busca democratizar el acceso a datos fiables y generar soluciones sostenibles que transformen las áreas más vulnerables en espacios dignos y habitables para las generaciones futuras.



4. RESULTADOS OBTENIDOS

4.1. CIUDADES DE BELICE Y BELMOPÁN

CIUDADES EN TRANSFORMACIÓN
Ciudad con limitadas opciones de vivienda asequible, lo que obliga a muchas personas a vivir fuera de la ciudad, ampliando aún más la huella urbana (BID, 2019)

Los resultados obtenidos, mediante la aplicación del *UNAIPS Methodology*, representan una cobertura² de 4.5% con relación al área total de los distritos de Belize y Cayo, en los que se ubican las ciudades analizadas de Belize y Belmopán, respectivamente. Se obtuvieron **169 polígonos de AP**, que abarcan una superficie total aproximada de 115.58 hectáreas, con alrededor de 1,817 estructuras de techos en total, que representan aproximadamente el 19.4 % de la superficie total de los polígonos de AP identificados (ver tabla 2 y figura 16).

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
Belize y Belmopán	115.58	22.42	19.4%

Tabla 2. Relación de superficie de polígonos AP y techos, para la ciudad de Belize y Belmopán. Fuente: ONU-Habitat, 2024.

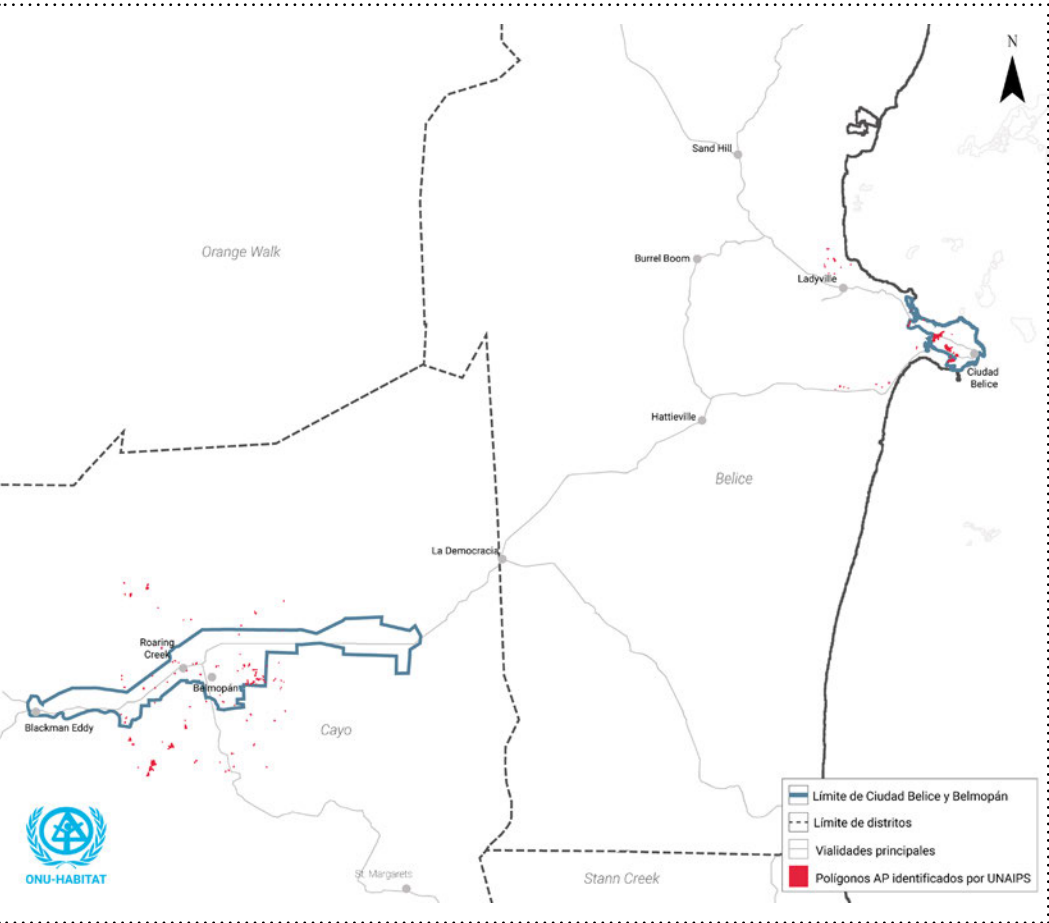
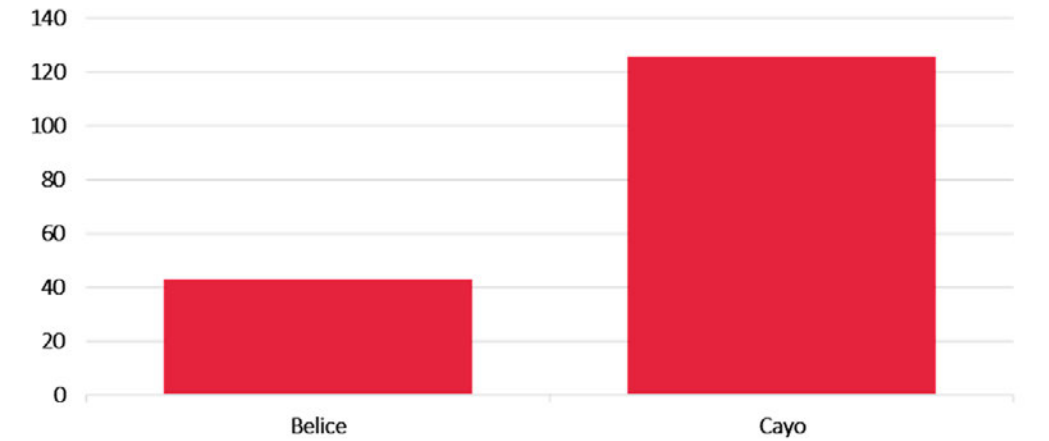


Figura 16. Asentamientos precarios identificados por *UNAIPS Methodology* en Ciudad de Belize y Belmopán. Fuente: ONU-Habitat, 2024.

² Como se ha señalado en secciones previas, la aplicación de *UNAIPS Methodology* depende de la disponibilidad de imágenes de satélite de alta resolución con buena calidad y cobertura, por lo cual, el algoritmo no pudo aplicarse para las zonas sin cobertura ni para las imágenes con nubosidad o características que imposibilitaron su adecuado funcionamiento.

La distribución geográfica de los polígonos de AP identificados, revela una concentración significativa en el distrito de Cayo, donde se localizan el 74.6% de los mismos. El resto se encuentra dentro del distrito de Belize. Esta distribución sugiere un patrón de crecimiento urbano hacia las zonas periféricas de Belmopán, lo que podría indicar una expansión de la huella urbana hacia áreas previamente no urbanizadas.




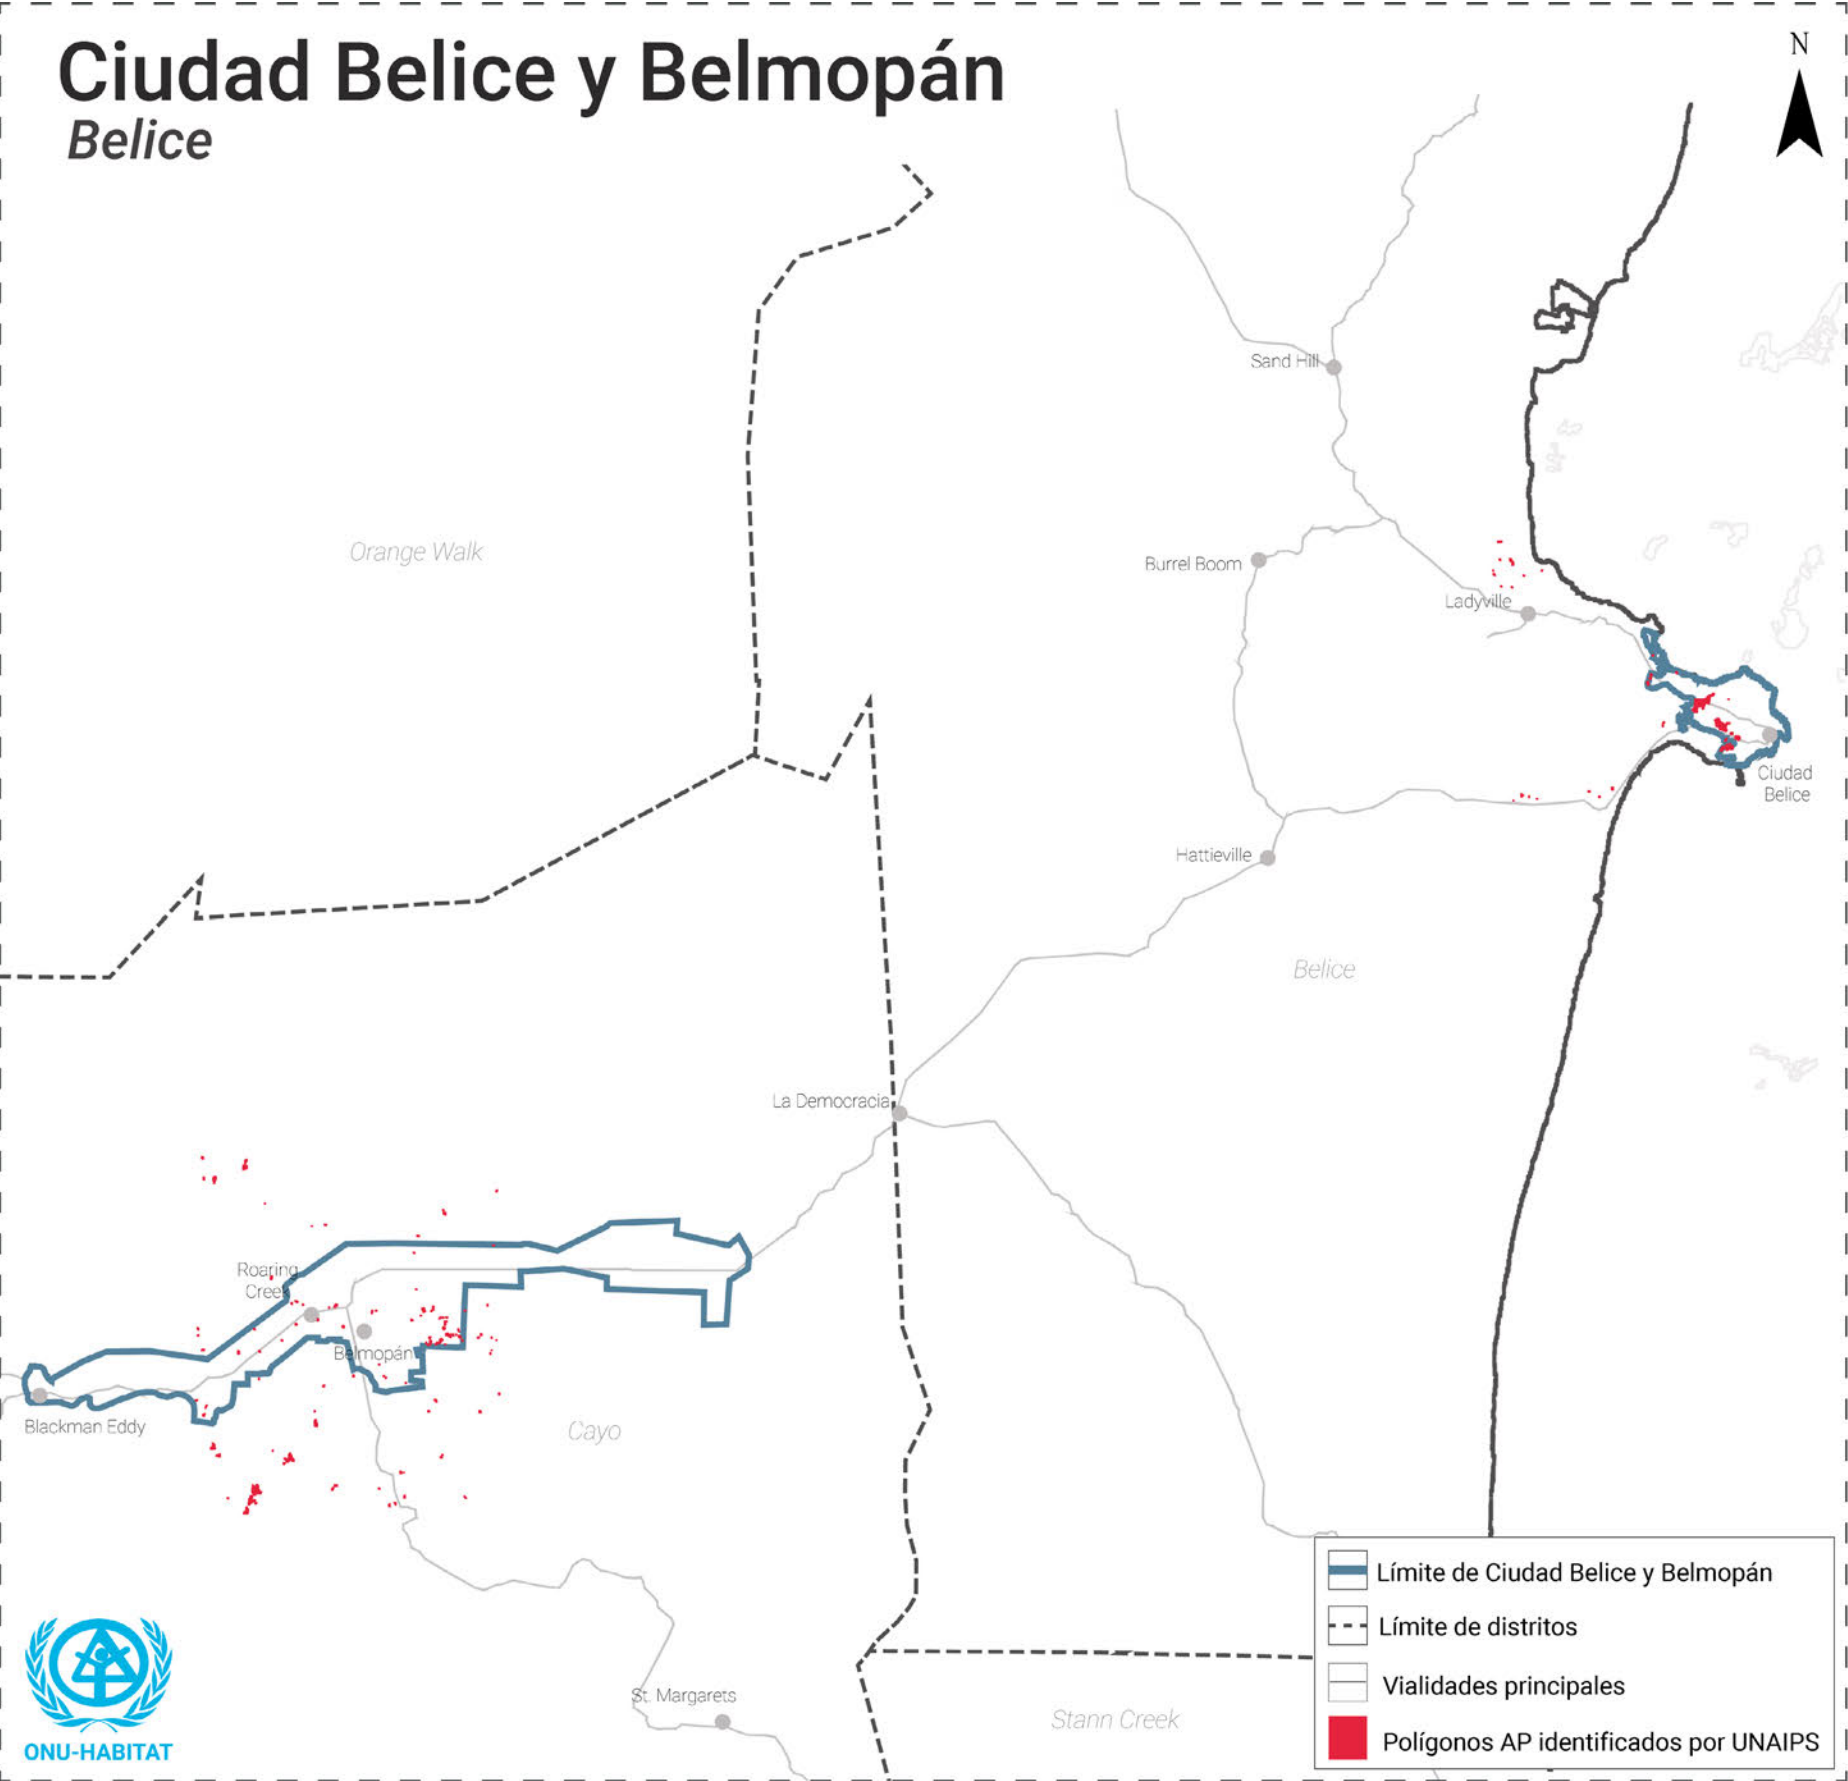
Gráfica 1. Distribución de asentamientos precarios identificados por distrito analizado dentro de la Ciudad de Belize y Belmopán Fuente: ONU-Habitat, 2024.

En cuanto a las características de estos asentamientos, es notable que, en promedio, cada asentamiento identificado presenta una superficie de edificaciones de aproximadamente 0.13 hectáreas, según los resultados obtenidos mediante el algoritmo *BEAM*. Además, se observa que la relación entre la superficie total de las edificaciones y el número de techos en el área analizada de las ciudades de Belize y Belmopán es de 0.012 hectáreas, con un nivel de precisión de 0.89. (Figura 17).



Figura 17. Ejemplos de superficie de techos/edificaciones identificadas en la zona central de ciudad Belize y en Belmopán. Fuente: ONU-Habitat, 2024.

Un análisis más detallado revela que la densidad de techos o superficie de edificaciones identificada varía significativamente según la ubicación del asentamiento. En particular, se observa que los asentamientos ubicados en Ciudad Belize presentan una mayor densidad, mientras que los ubicados en Belmopán muestran una densidad más baja. Esta variación sugiere patrones de ocupación y desarrollo urbano diferenciados entre ambas ciudades.



4.2. GRAN ÁREA METROPOLITANA DE SAN JOSÉ

¿CIUDAD PARA TODOS?
El terreno en que se ubican los asentamientos precario y tugurios y sus condiciones físicas son un factor determinante e histórico en la consolidación social, la legalización y las mejoras de la infraestructura y vivienda.
(MIVAH, 2005)

La Gran Área Metropolitana (GAM) de San José fue una de las primeras ciudades donde se implementó con éxito la [UNAIPS Methodology](#) y se obtuvieron los primeros resultados automatizados de polígonos de AP. Se obtuvieron en total, **260 polígonos AP** que cubren una superficie total de 194.21 hectáreas en la Gran Área Metropolitana (GAM) de San José. Dentro de estos polígonos de AP, se logró identificar y extraer un total de 10,128 estructuras de techos, lo que representa un avance significativo en la detección de características urbanas. Es importante destacar que estas estructuras identificadas son el 37.9% de la superficie total de los polígonos AP (ver tabla 3 y Figura 18).

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
GAM de San José	194.21	73.62	37.9%

Tabla 3. Relación de superficie de polígonos AP y techos, para la GAM de San José, Costa Rica.
Fuente: ONU-Habitat, 2024.

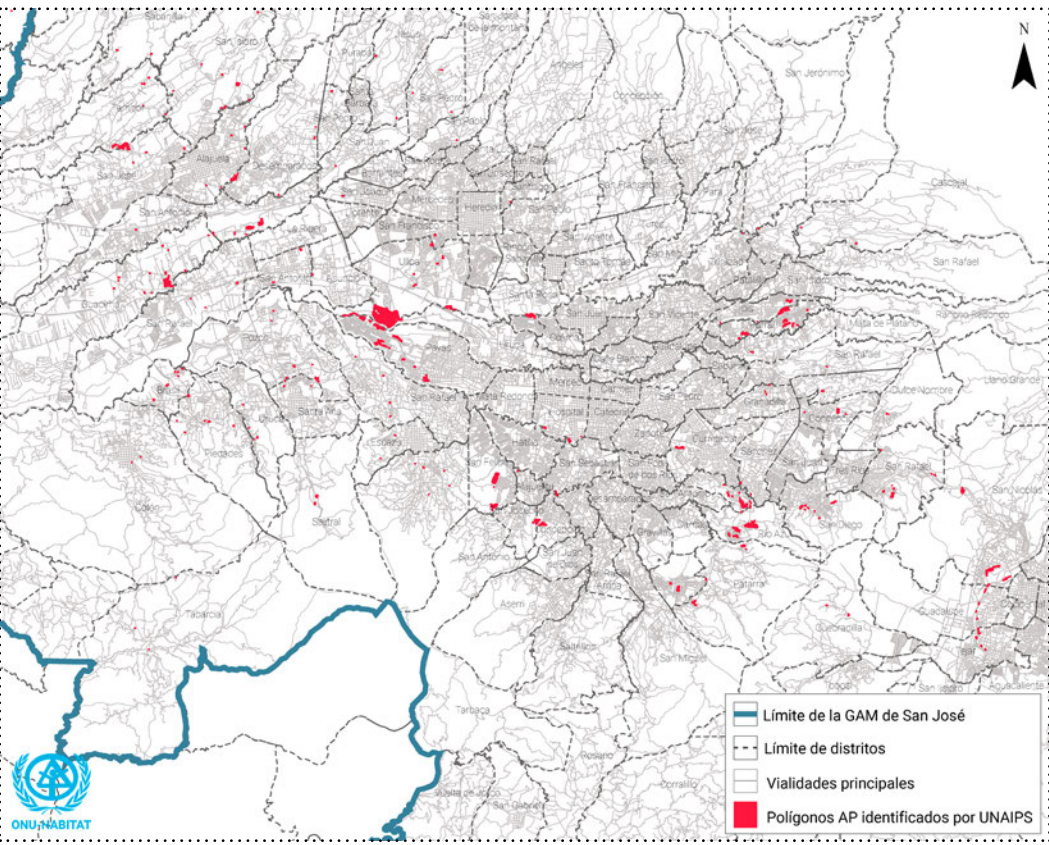
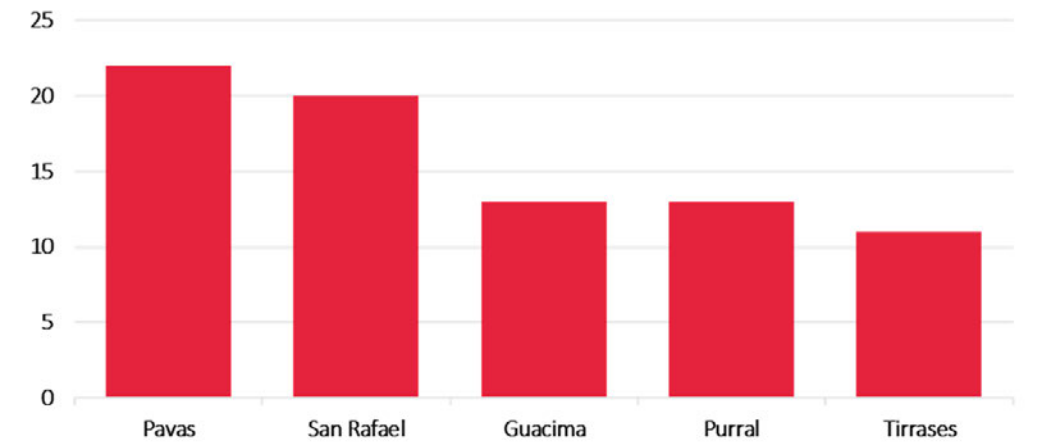


Figura 18. Asentamientos precarios identificados por [UNAIPS Methodology](#) en la GAM de San José, Costa Rica.
Fuente: ONU-Habitat, 2024.

Dentro de la Gran Área Metropolitana (GAM) de San José, los distritos que resultaron con el mayor número de polígonos AP son Pavas, San Rafael, Guacima, Purral y Tirrases. En conjunto, estos distritos concentran el 28.6% de los polígonos AP identificados, destacándose como áreas con una mayor presencia de asentamientos precarios en el país. El resto de los polígonos AP se distribuye en 51 distritos adicionales, que presentan una menor concentración de estos polígonos (ver gráfica 2).

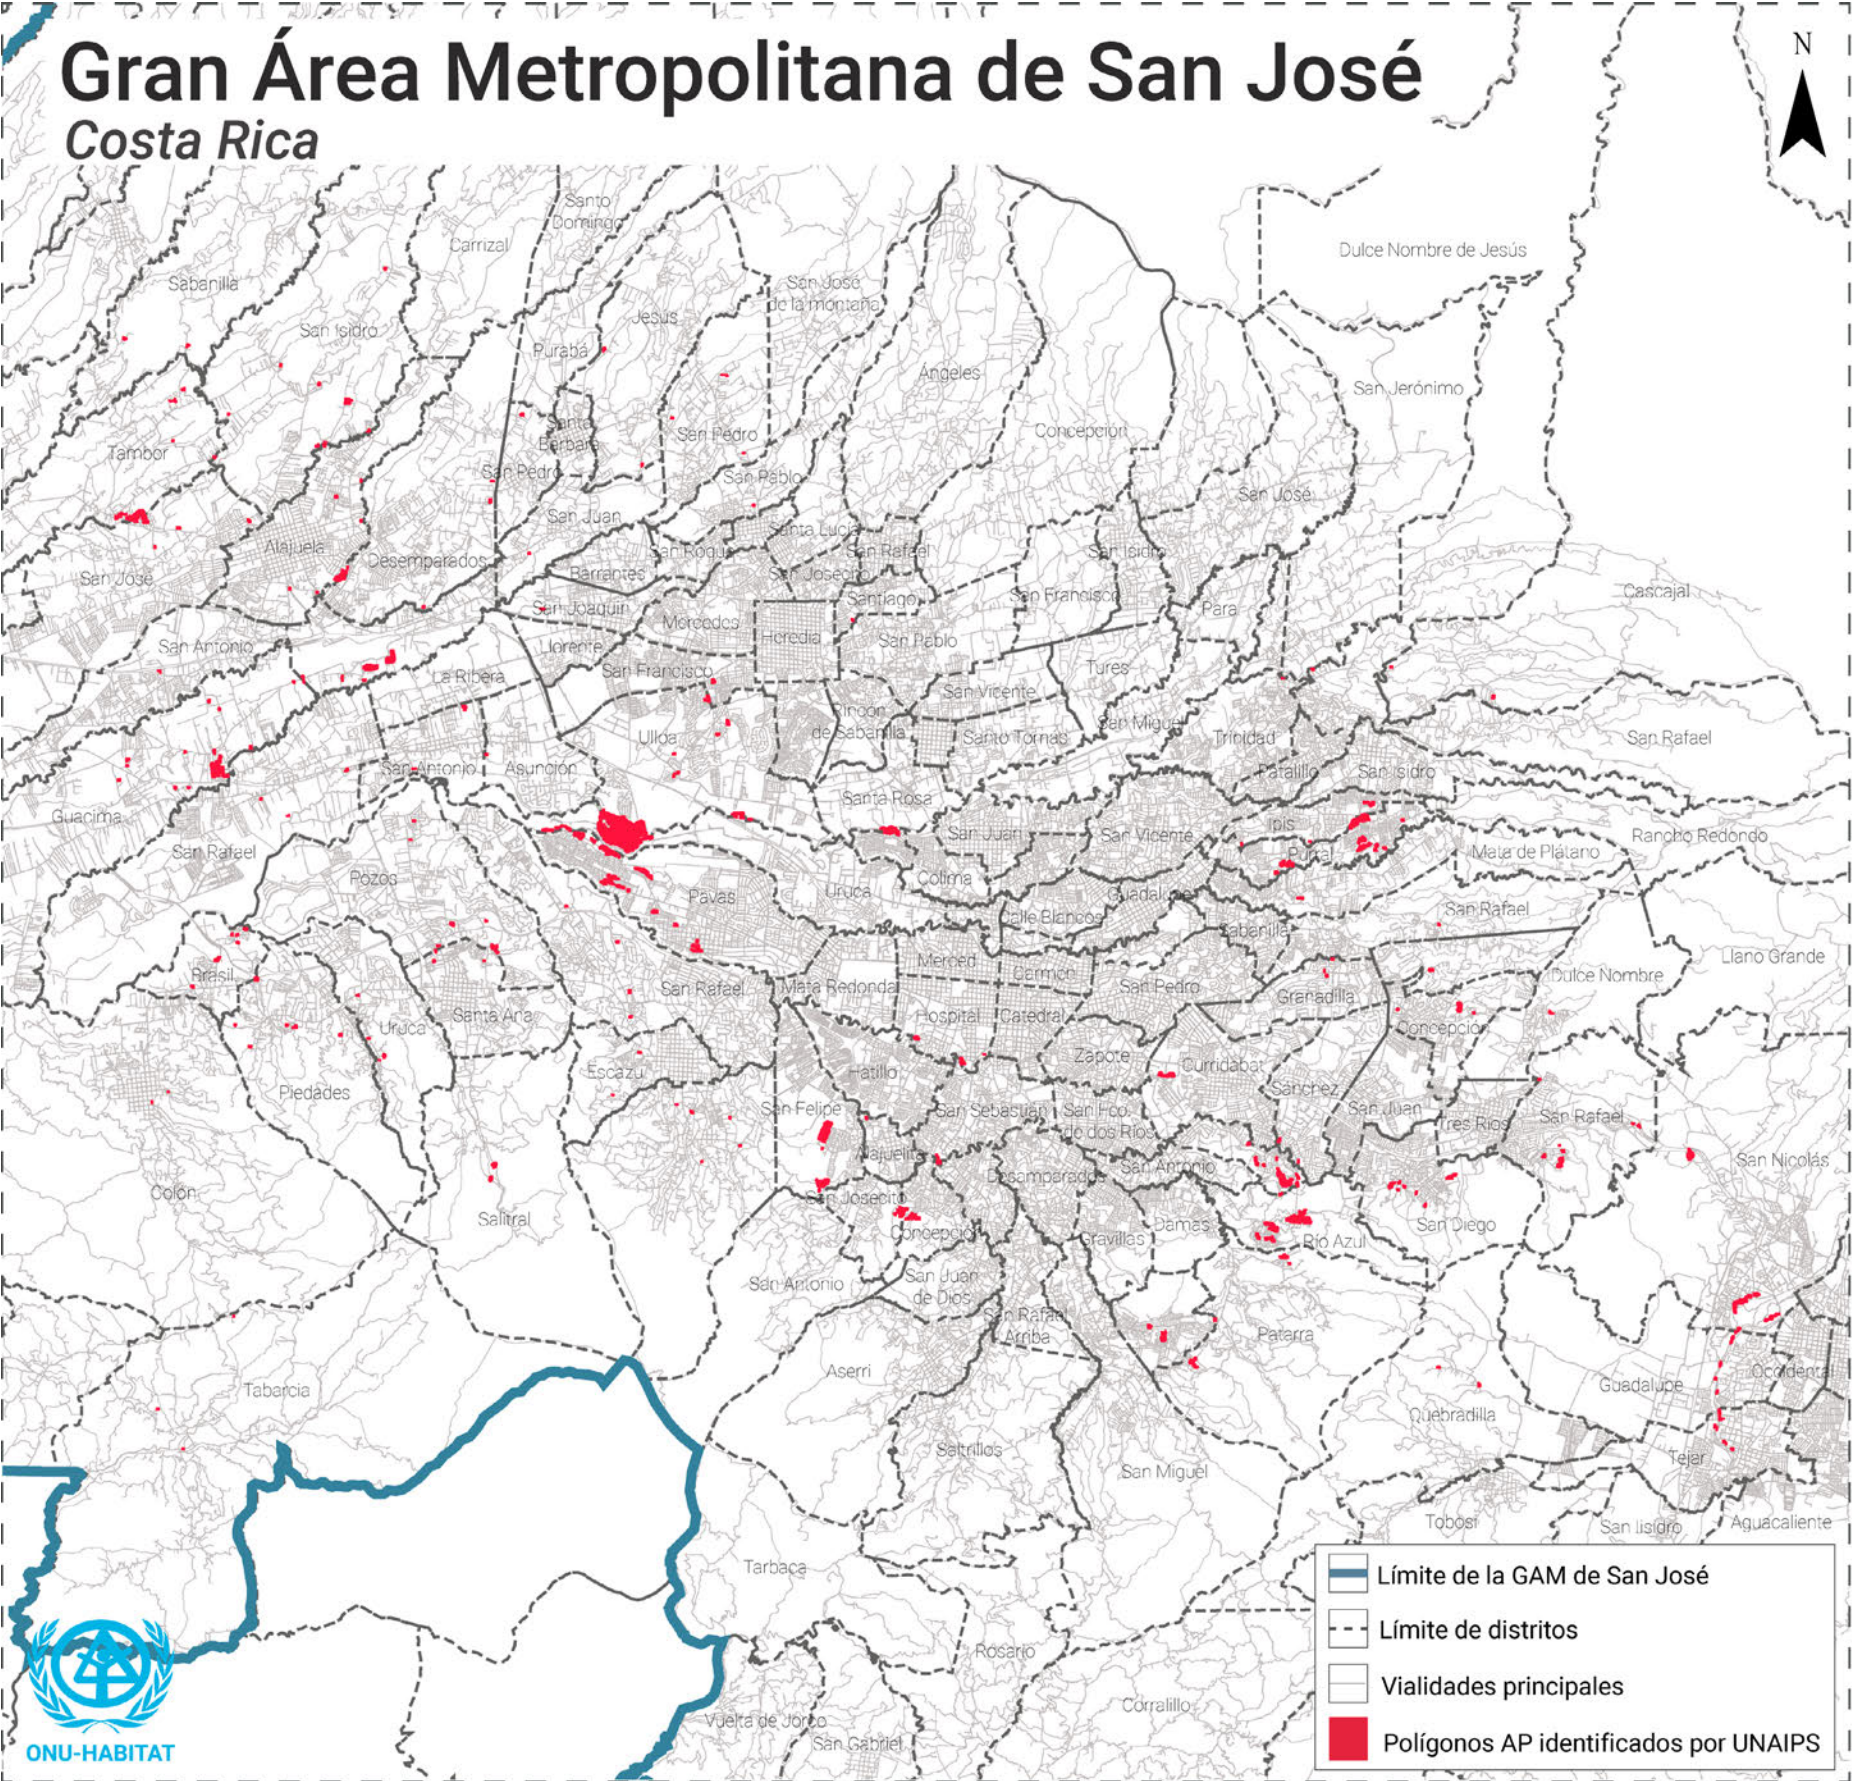


Gráfica 2. Distribución de asentamientos precarios identificados por distrito analizado dentro de la GAM de San José, Costa Rica.
Fuente: ONU-Habitat, 2024.

En cuanto a las características de los asentamientos identificados, destaca que de acuerdo con los resultados obtenidos mediante el algoritmo *BEAM*, cada asentamiento presenta, en promedio, una superficie de edificaciones de aproximadamente 0.28 hectáreas. Además, se observa una relación de 0.007 hectáreas entre la superficie total de las edificaciones y el número de techos en el área analizada de la GAM de San José (ver figura 19).






Figura 19. Ejemplos de superficie de techos/edificaciones identificadas en la GAM de San José, Costa Rica.
Fuente: ONU-Habitat, 2024.



El GAM de San José presentó **260** polígonos de asentamientos precarios (AP), con una superficie de **194.21 ha**. Los polígonos de **techos** cubren el **37.9%** de los polígonos AP.

Para la generación de los polígonos AP, se utilizaron **imágenes de satélite** WorldView-2, las cuales ofrecieron una cobertura del **44.9 %** con respecto al **área metropolitana**.



4.3.ÁREA METROPOLITANA DE SAN SALVADOR

CIUDAD DE CAMBIOS URBANOS
El enmascaramiento de la pobreza urbana se ha debido a que, en comparación con las zonas rurales, las ciudades ofrecen a los pobres mejores servicios educativos y opciones de empleo más diversas. (PNUD, 2009)

El AMSS, tiene una superficie de 59,740 hectáreas y se logró un cubrimiento con imágenes de satélite disponibles, de un 90% de cobertura. Como resultado, se logró la identificación de **1,195 polígonos AP** a través de *UNAIPS Methodology*, distribuidos en 14 municipios (ver figura 20).

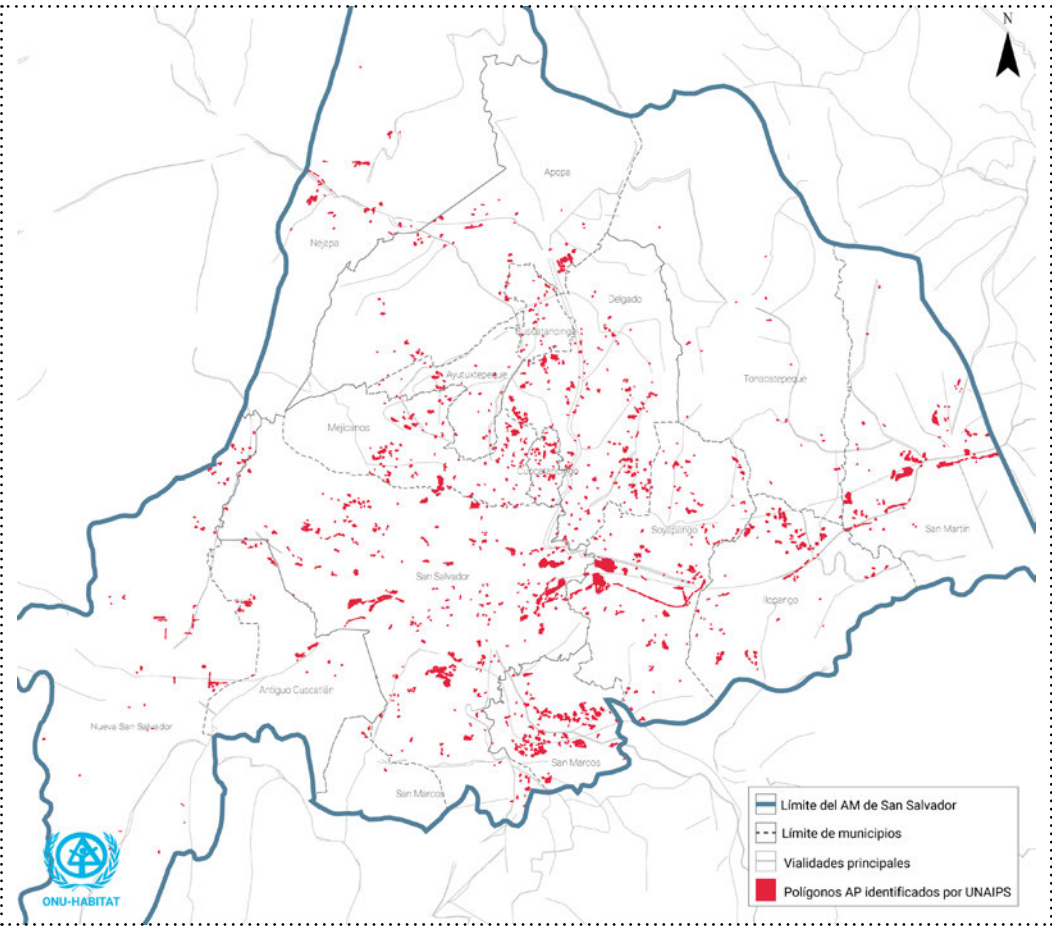
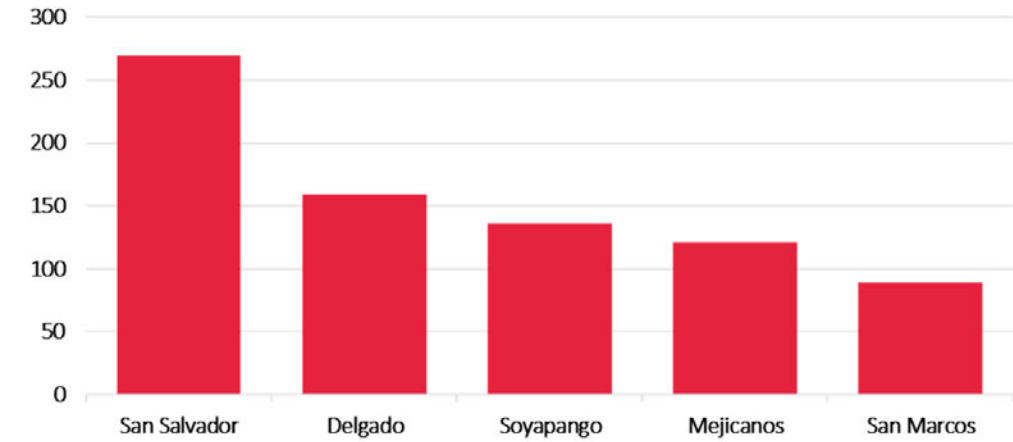


Figura 20. Asentamientos precarios identificados por *UNAIPS Methodology* en el AMSS, El Salvador. Fuente: ONU-Habitat, 2024.

Es notable que solo 5 municipios concentran la mayor cantidad de polígonos AP detectados, específicamente San Salvador, Delgado, Soyapango, Mejicanos y San Marcos, que en conjunto representan el 63.3% del total de polígonos AP identificados (Gráfica 3).



Gráfica 3. Distribución de asentamientos precarios identificados por municipio analizado dentro de AMSS, El Salvador. Fuente: ONU-Habitat, 2024

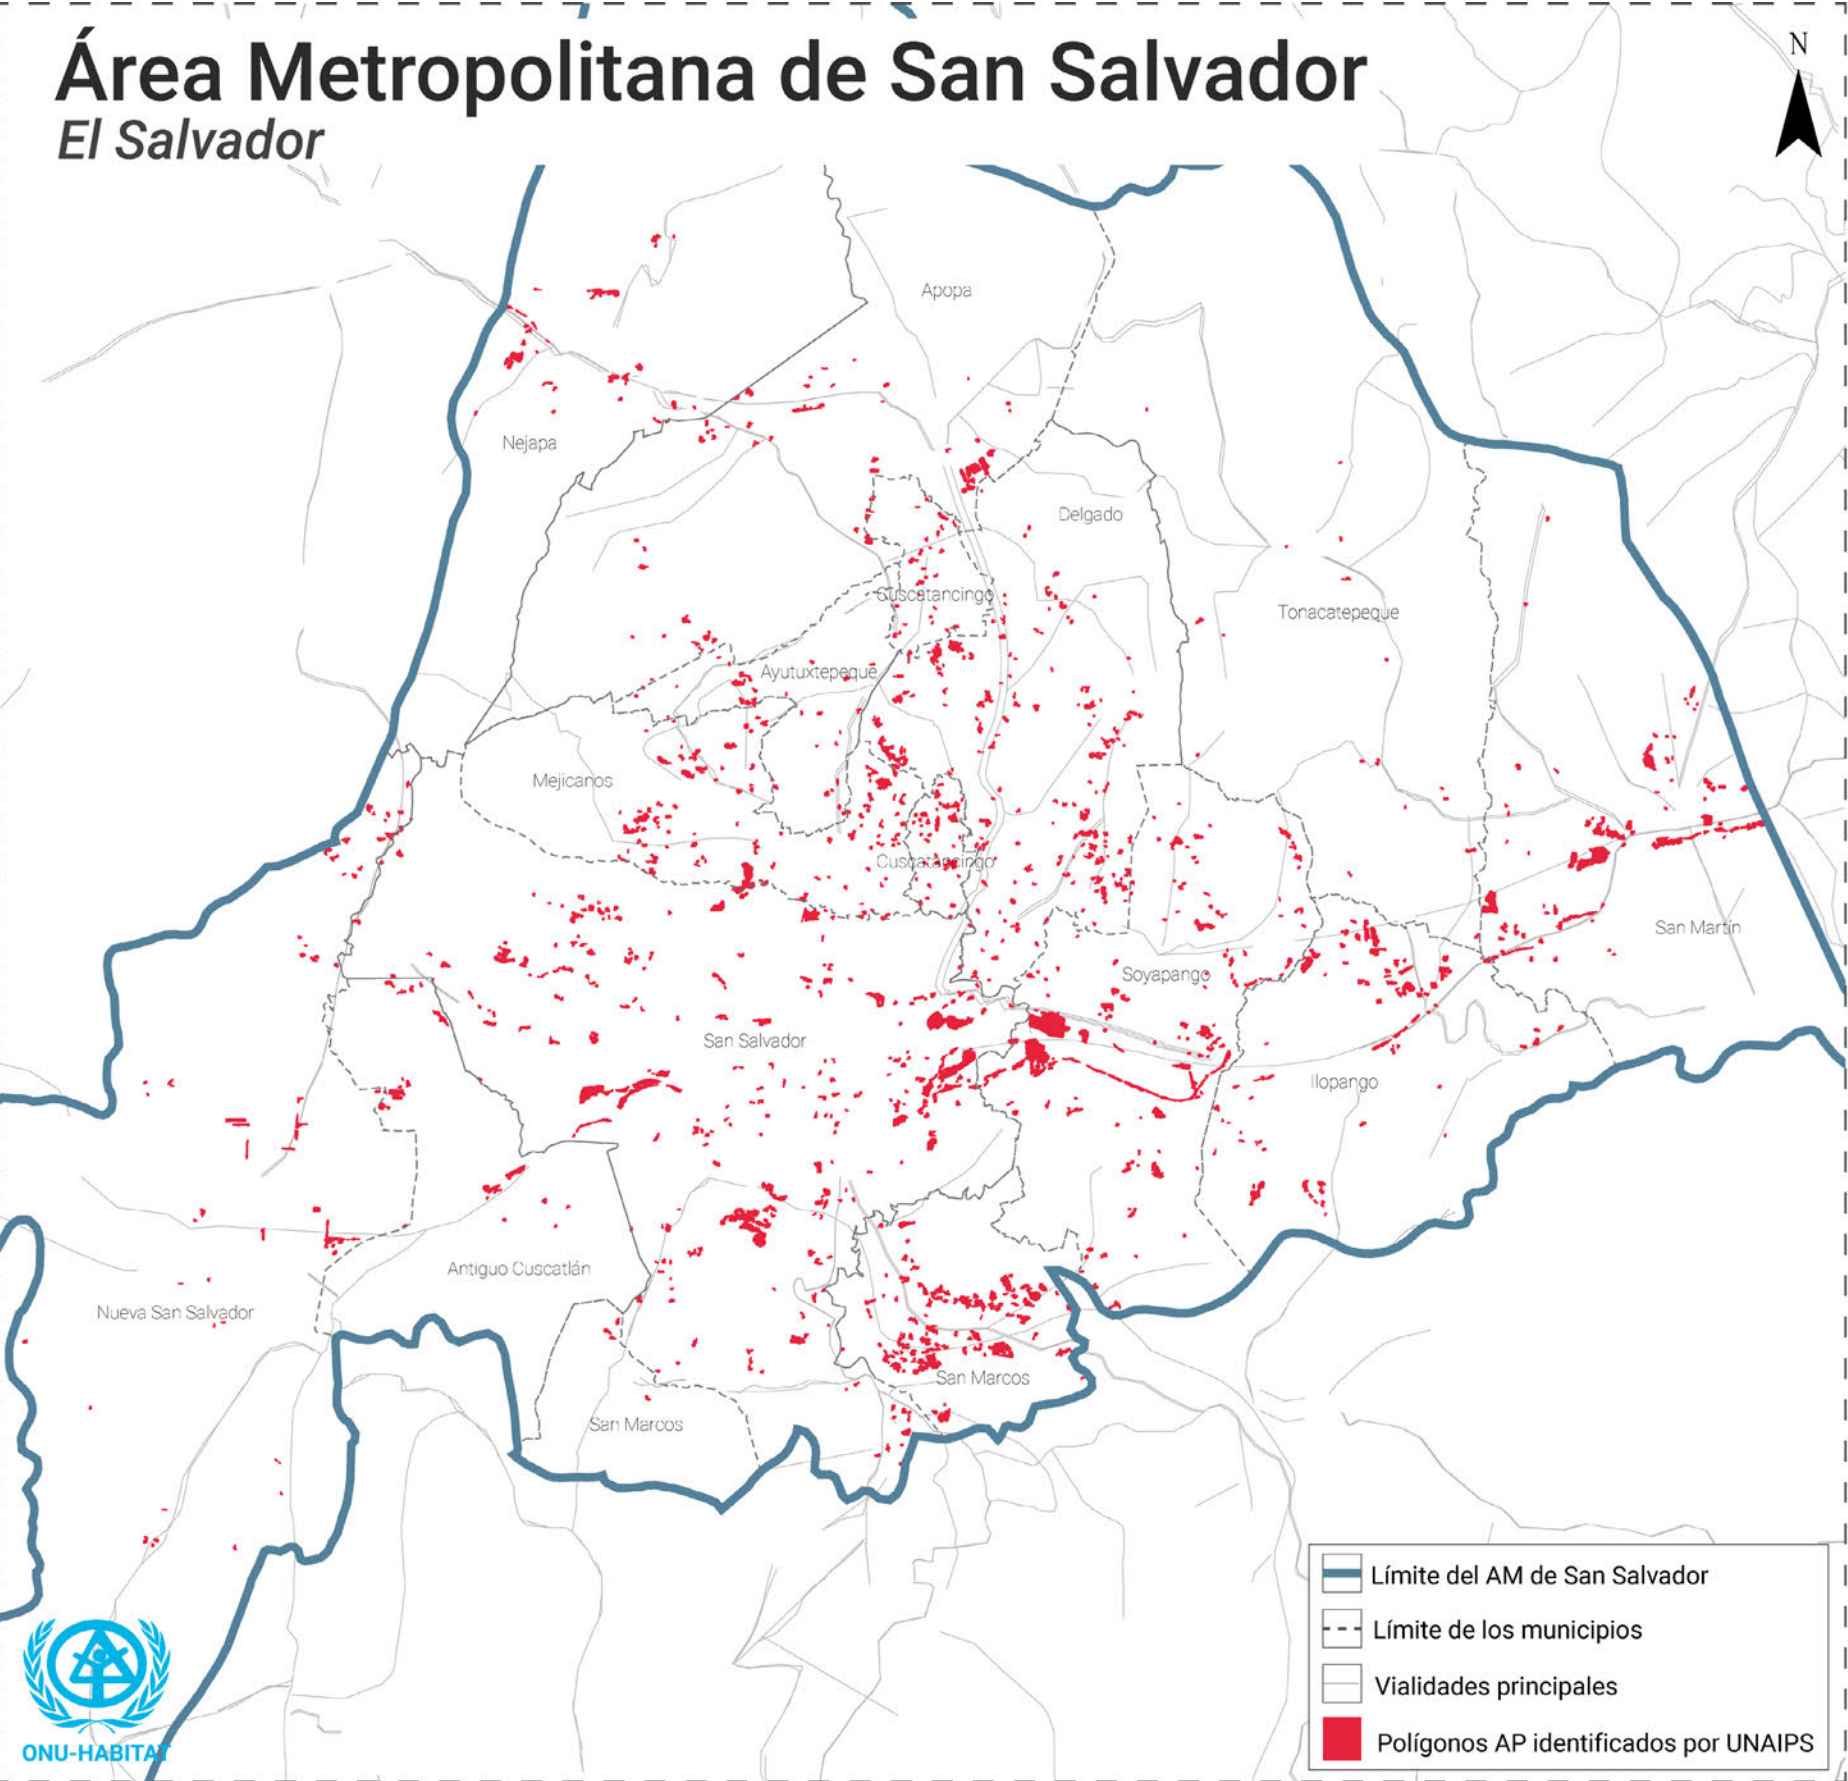
Dentro de la superficie de los polígonos AP, se identificaron 62,143 estructuras de techos, lo que representa un cubrimiento del 26.4% de la superficie total de los polígonos (tabla 4). Estos resultados revelan patrones significativos en los asentamientos identificados en la AMSS de El Salvador. En términos de superficie, cada asentamiento presenta un promedio de 0.16 hectáreas de edificaciones. Además, se ha detectado una relación significativa entre la superficie total de las edificaciones y el número de techos en el área analizada, con una proporción de 0.003 hectáreas por techo. (Ver figura 21).

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
AM de San Salvador	715.16	188.60	26.4%

Tabla 4. Relación de superficie de polígonos AP y techos, para el AMSS, El Salvador. Fuente: ONU-Habitat, 2024

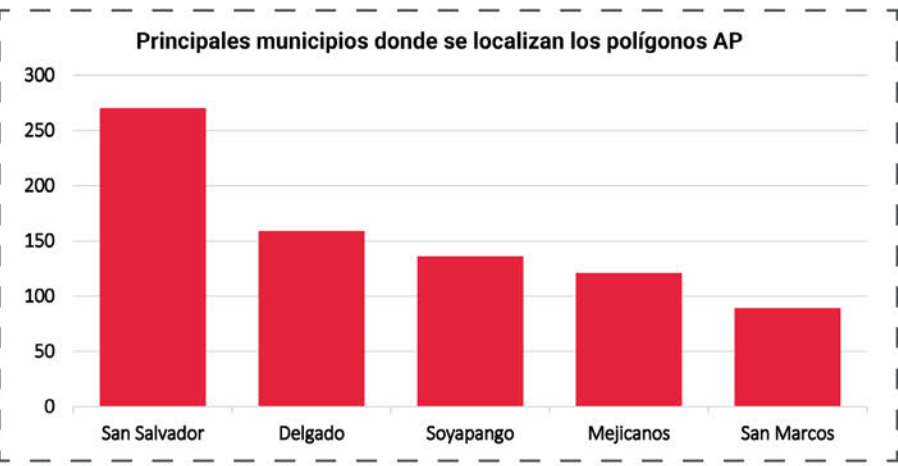




Figura 21. Ejemplos de superficie de techos/edificaciones identificadas en el AMSS, El Salvador. Fuente: ONU-Habitat, 2024.



El **AM de San Salvador** presentó **1,195** polígonos de asentamientos precarios (AP), con una superficie de **715.16 ha**. Los polígonos de **techos** cubren el **26.4%** de los polígonos AP.

Para la generación de los polígonos AP, se utilizaron **imágenes de satélite** WorldView-2, las cuales ofrecieron una cobertura del **90.0 %** con respecto al **área metropolitana**.



4.4.ZONA METROPOLITANA DE LA CIUDAD DE GUATEMALA

CIUDAD PRECARIA EN LA PERIFERIA

La población pobre tiende a establecerse en zonas periféricas de los municipios más poblados del área metropolitana, sobre una trama urbana que carece de servicios básicos y/o se ubica en zonas de riesgo, como resultado de las condiciones socioeconómicas de la población, así como del alto costo de las viviendas respecto de los niveles de ingreso. (ORTEGA, 2014)

Los resultados obtenidos de la identificación de asentamientos precarios en Zona Metropolitana de la ciudad de Guatemala (ZMCG) a través de [UNAIPS Methodology](#), cuya cobertura analizada es del 75.4 % de la superficie total aproximada de la zona metropolitana (integrada por 5 municipios), muestra que las zonas precarias se ubican principalmente, en zonas periféricas, y con menor intensidad en las zonas núcleo o más internas del polígono urbano. Se identificaron en total, 249 asentamientos precarios, de los cuales, al menos el 56.3% de ellos, se ubicaron en el municipio de Guatemala, corazón de la zona metropolitana (ver gráfica 4 y figura 22).



Gráfica 4. Distribución de asentamientos precarios identificados por municipio dentro de la ZMCG. Fuente: ONU-Habitat, 2024.

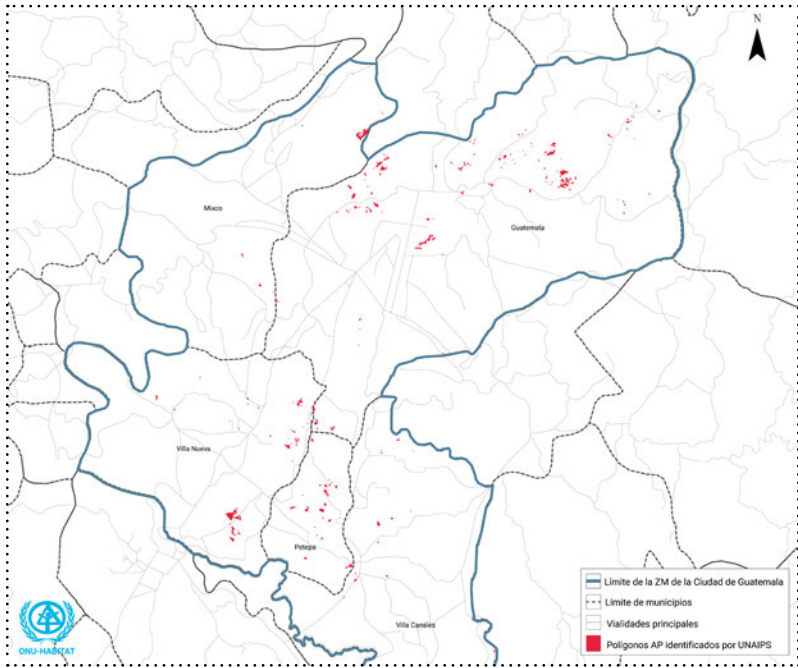


Figura 22. Asentamientos precarios identificados por [UNAIPS Methodology](#) en la ZMCG. Fuente: ONU-Habitat, 2024.

En esta zona metropolitana, los polígonos de asentamientos precarios abarcan un total de 169.20 hectáreas, con una cobertura de techos que alcanza el 91.6% de la superficie total de estos polígonos AP, como se puede observar en la tabla siguiente:


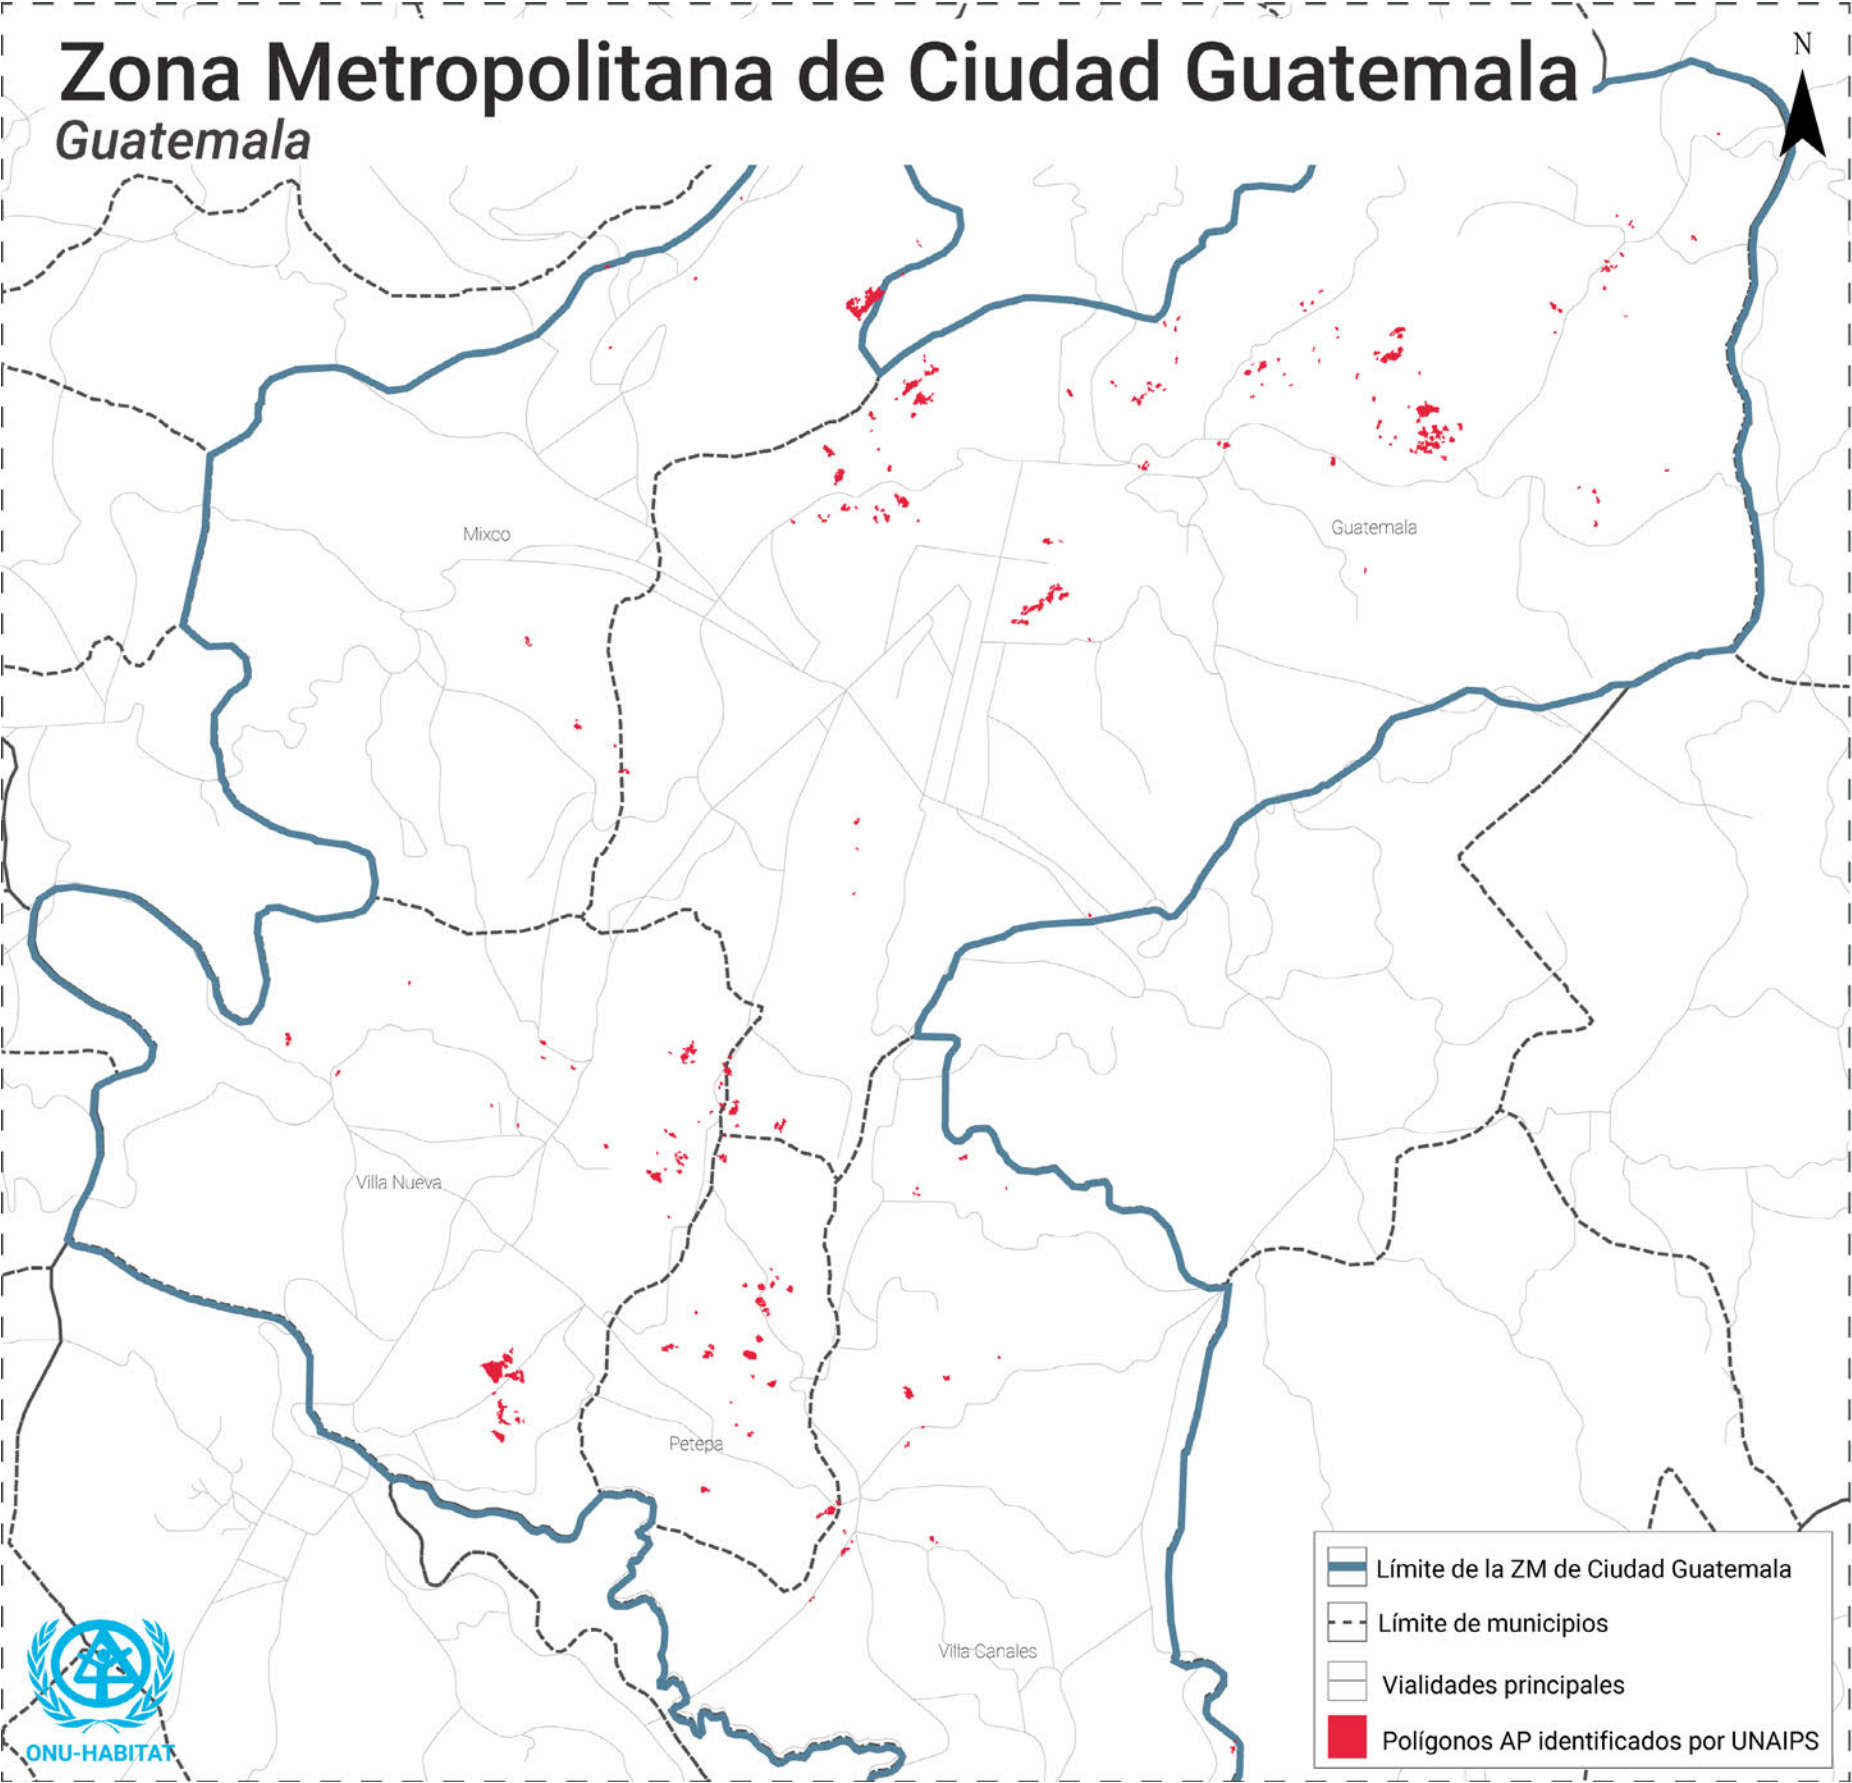
CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
ZM de Ciudad Guatemala	169.20	154.99	91.6%

Tabla 5. Relación de superficie de polígonos AP y techos, para la ZM de la Ciudad de Guatemala Fuente: ONU-Habitat, 2024.

En cuanto a las características de estos asentamientos es de señalar que, en promedio, cada polígono de asentamiento identificado posee 0.61 hectáreas de edificaciones, según lo obtenido por el algoritmo *BEAM* y que el número de superficie total/número de techos de edificaciones para la superficie analizada dentro de la ZM de la ciudad de Guatemala, es de 0.006 hectáreas de edificaciones, con una precisión de 0.83. Se observa que el número de techos o superficie de edificaciones identificada, varían en función de la ubicación del asentamiento, siendo mucho más alto el valor en los asentamientos ubicados en la zona núcleo de la zona metropolitana y mucho más bajo, conforme se ubica en la periferia.



Figura 23. Ejemplo de superficie de techos/edificaciones identificadas en zonas centrales y periféricas de la ZM de la Ciudad de Guatemala. Fuente: ONU-Habitat, 2024.



4.5. ZONA METROPOLITANA DISTRITO CENTRAL (TEGUCIGALPA Y COMAYAGÜELA)

CIUDAD EN RECONSTRUCCIÓN

La precariedad y la informalidad de los asentamientos humanos extendidas en nuestras ciudades constituyen un fenómeno histórico que ha sido retomado en diversos contextos; conocerlo, reconocerlo y abordarlo estratégicamente es relevante para la construcción de una ciudad más justa, equitativa y democrática. (AECID 2022)

Según los resultados obtenidos mediante el [UNAIPS Methodology](#) para esta ciudad, se identificaron **312 polígonos** de asentamientos precarios que cubren un total de 83.88 hectáreas. Además, se detectaron 8,032 estructuras de techos dentro de estos polígonos, lo que representa el 54.5% de la superficie total de los asentamientos precarios (ver tabla 6 y figura 24).

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
ZM de Distrito Central	83.88	45.72	54.5%

Tabla 6. Relación de superficie de polígonos AP y techos para la ZM Distrito Central, Honduras. Fuente: ONU-Habitat, 2024.

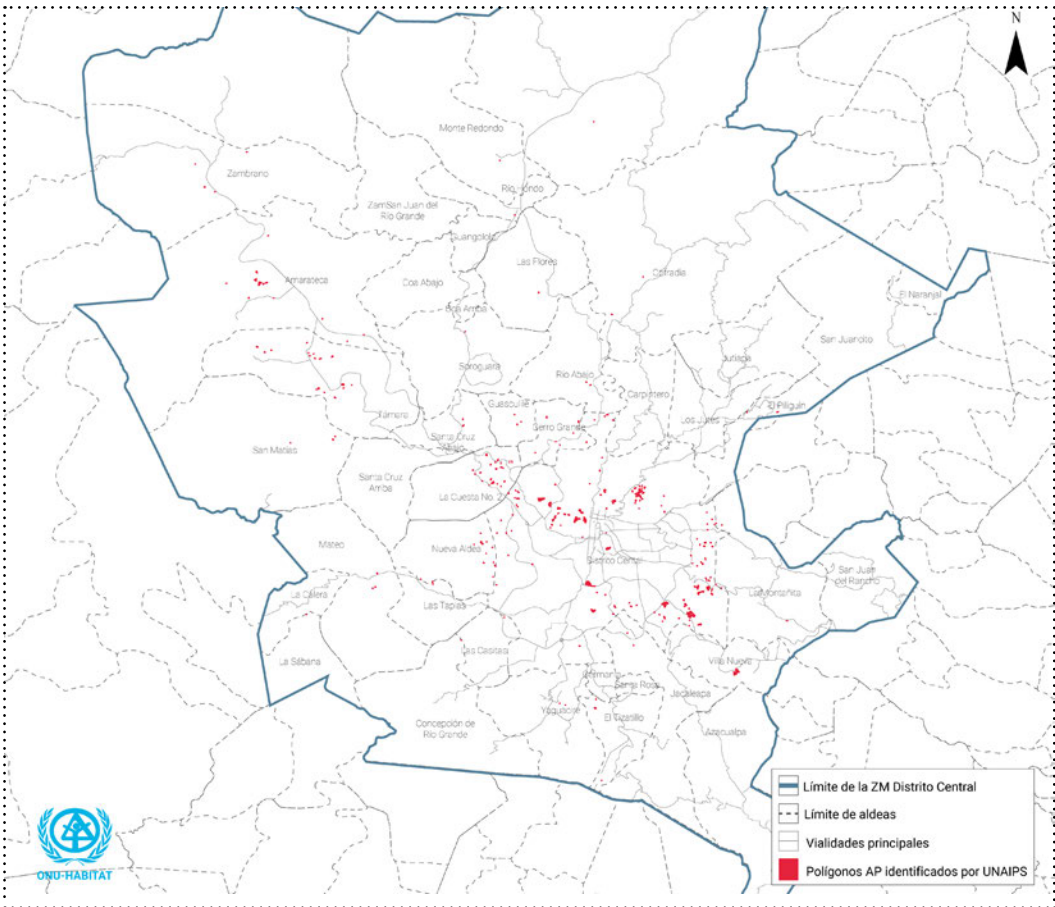



Figura 24. Asentamientos precarios identificados por [UNAIPS Methodology](#) en la ZM Distrito Central, Honduras. Fuente: ONU-Habitat, 2024

La distribución de los polígonos AP se extiende a 28 aldeas de la zona metropolitana, con una concentración del 79% en las aldeas de Distrito Central, La Cuesta No. 2, Támara, Amarateca y Nueva Aldea, como se muestra en la gráfica 5.


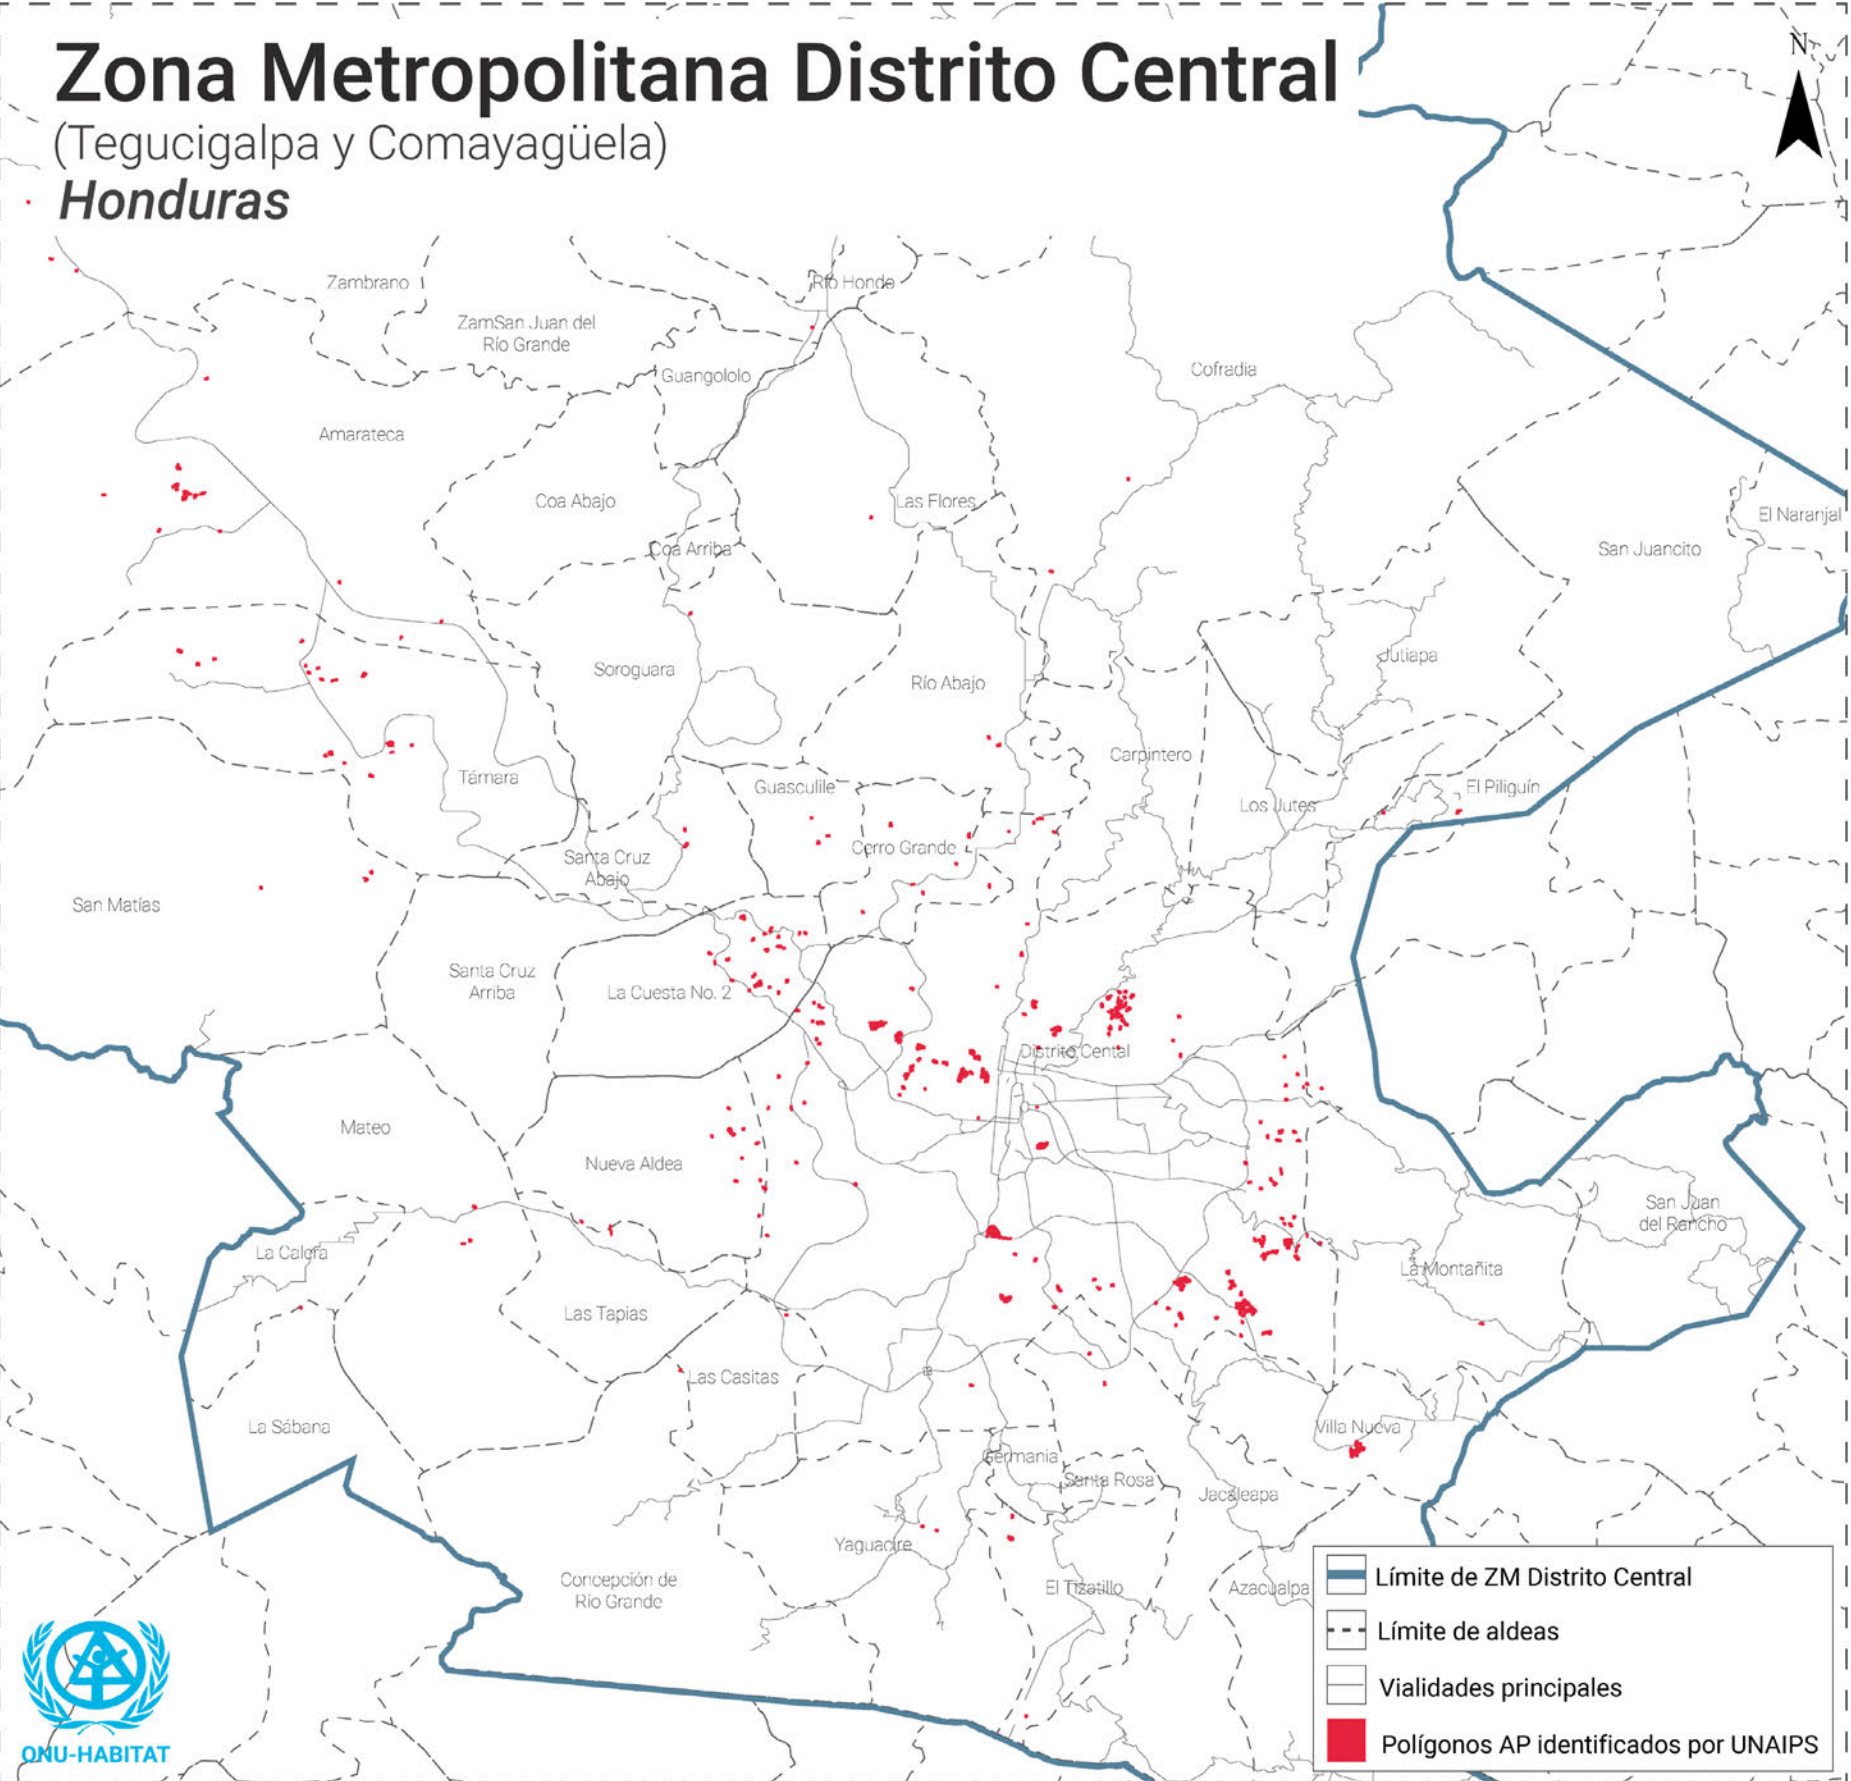


Gráfica 5. Distribución de asentamientos precarios identificados por aldea analizada dentro de la ZM Distrito Central, Honduras. Fuente: ONU-Habitat, 2024.

En cuanto a las características de los asentamientos identificados, destaca que de acuerdo con los resultados obtenidos mediante el algoritmo *BEAM*, cada asentamiento presenta, en promedio, una superficie de edificaciones de aproximadamente 0.15 hectáreas. Además, se observa una relación de 0.006 hectáreas entre la superficie total de las edificaciones y el número de techos en el área analizada de la GAM de San José, con una precisión de 0.82. Ejemplo en la siguiente figura.



Figura 25. Ejemplo de superficie de techos/edificaciones identificadas en la ZM Distrito Central, Honduras. Fuente: ONU-Habitat, 2024.



4.6.REGIÓN METROPOLITANA DE MANAGUA

CIUDAD PARA SU POBLACIÓN
Los habitantes de los asentamientos son quienes mejores conocen y pueden identificar sus problemáticas además de reconocer las fortalezas que les ha permitido mejorar su hábitat.
(TECHO-UCA 2015)

En la Región Metropolitana de Managua, el uso del [UNAIPS Methodology](#) permitió obtener **833 polígonos** de asentamientos precarios que cubren una superficie total de 320.08 hectáreas en la región. Dentro de estos polígonos AP, se identificaron y extrajeron 17,683 estructuras de techos, lo que representa un avance significativo en la detección de características urbanas. Es importante destacar que estas estructuras identificadas representan el 25.3% de la superficie total de los polígonos AP (ver tabla 7 y figura 26).

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
RM de Managua	320.08	80.88	25.3%

Tabla 7. Relación de superficie de polígonos AP y techos para la RM de Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.

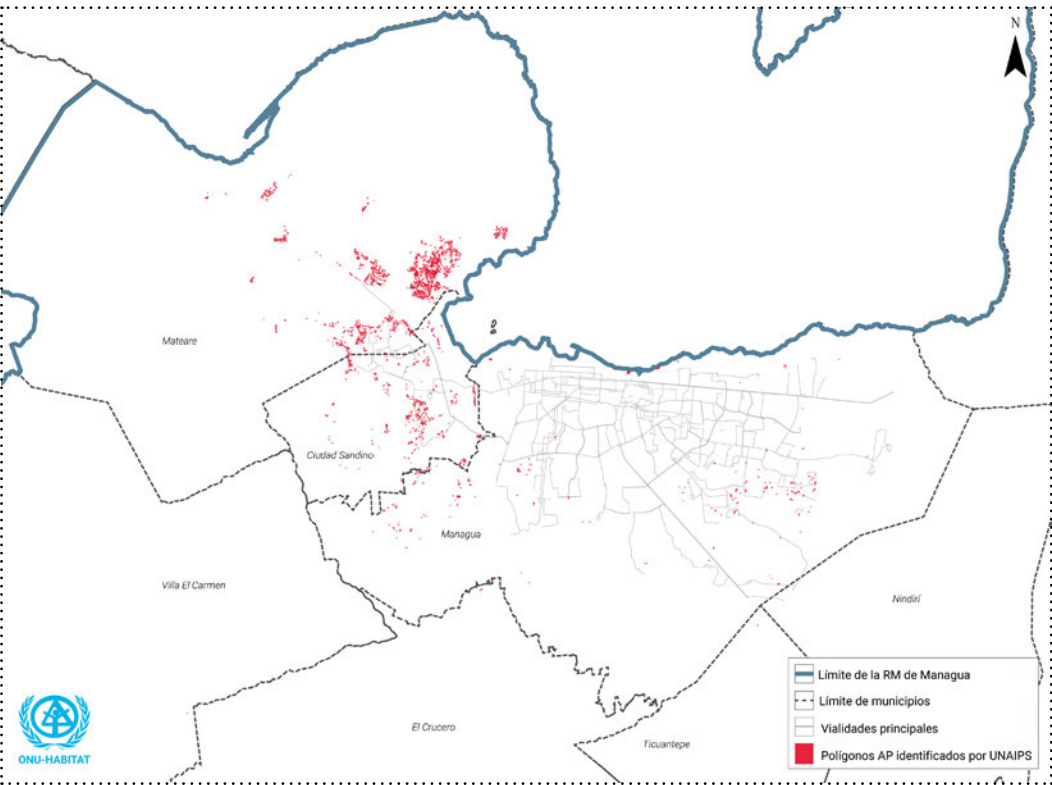



Figura 26. Asentamientos precarios identificados por [UNAIPS Methodology](#) en la RM de Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.

La distribución de los polígonos AP en la RM de Managua muestra que los municipios con la mayor concentración de asentamientos precarios son Mateare, Ciudad Sandino, Managua, Villa El Carmen y El Crucero. En conjunto, estos distritos concentran el 99.9% de los polígonos AP, destacándose como áreas con un mayor número de asentamientos precarios (ver gráfica 6).

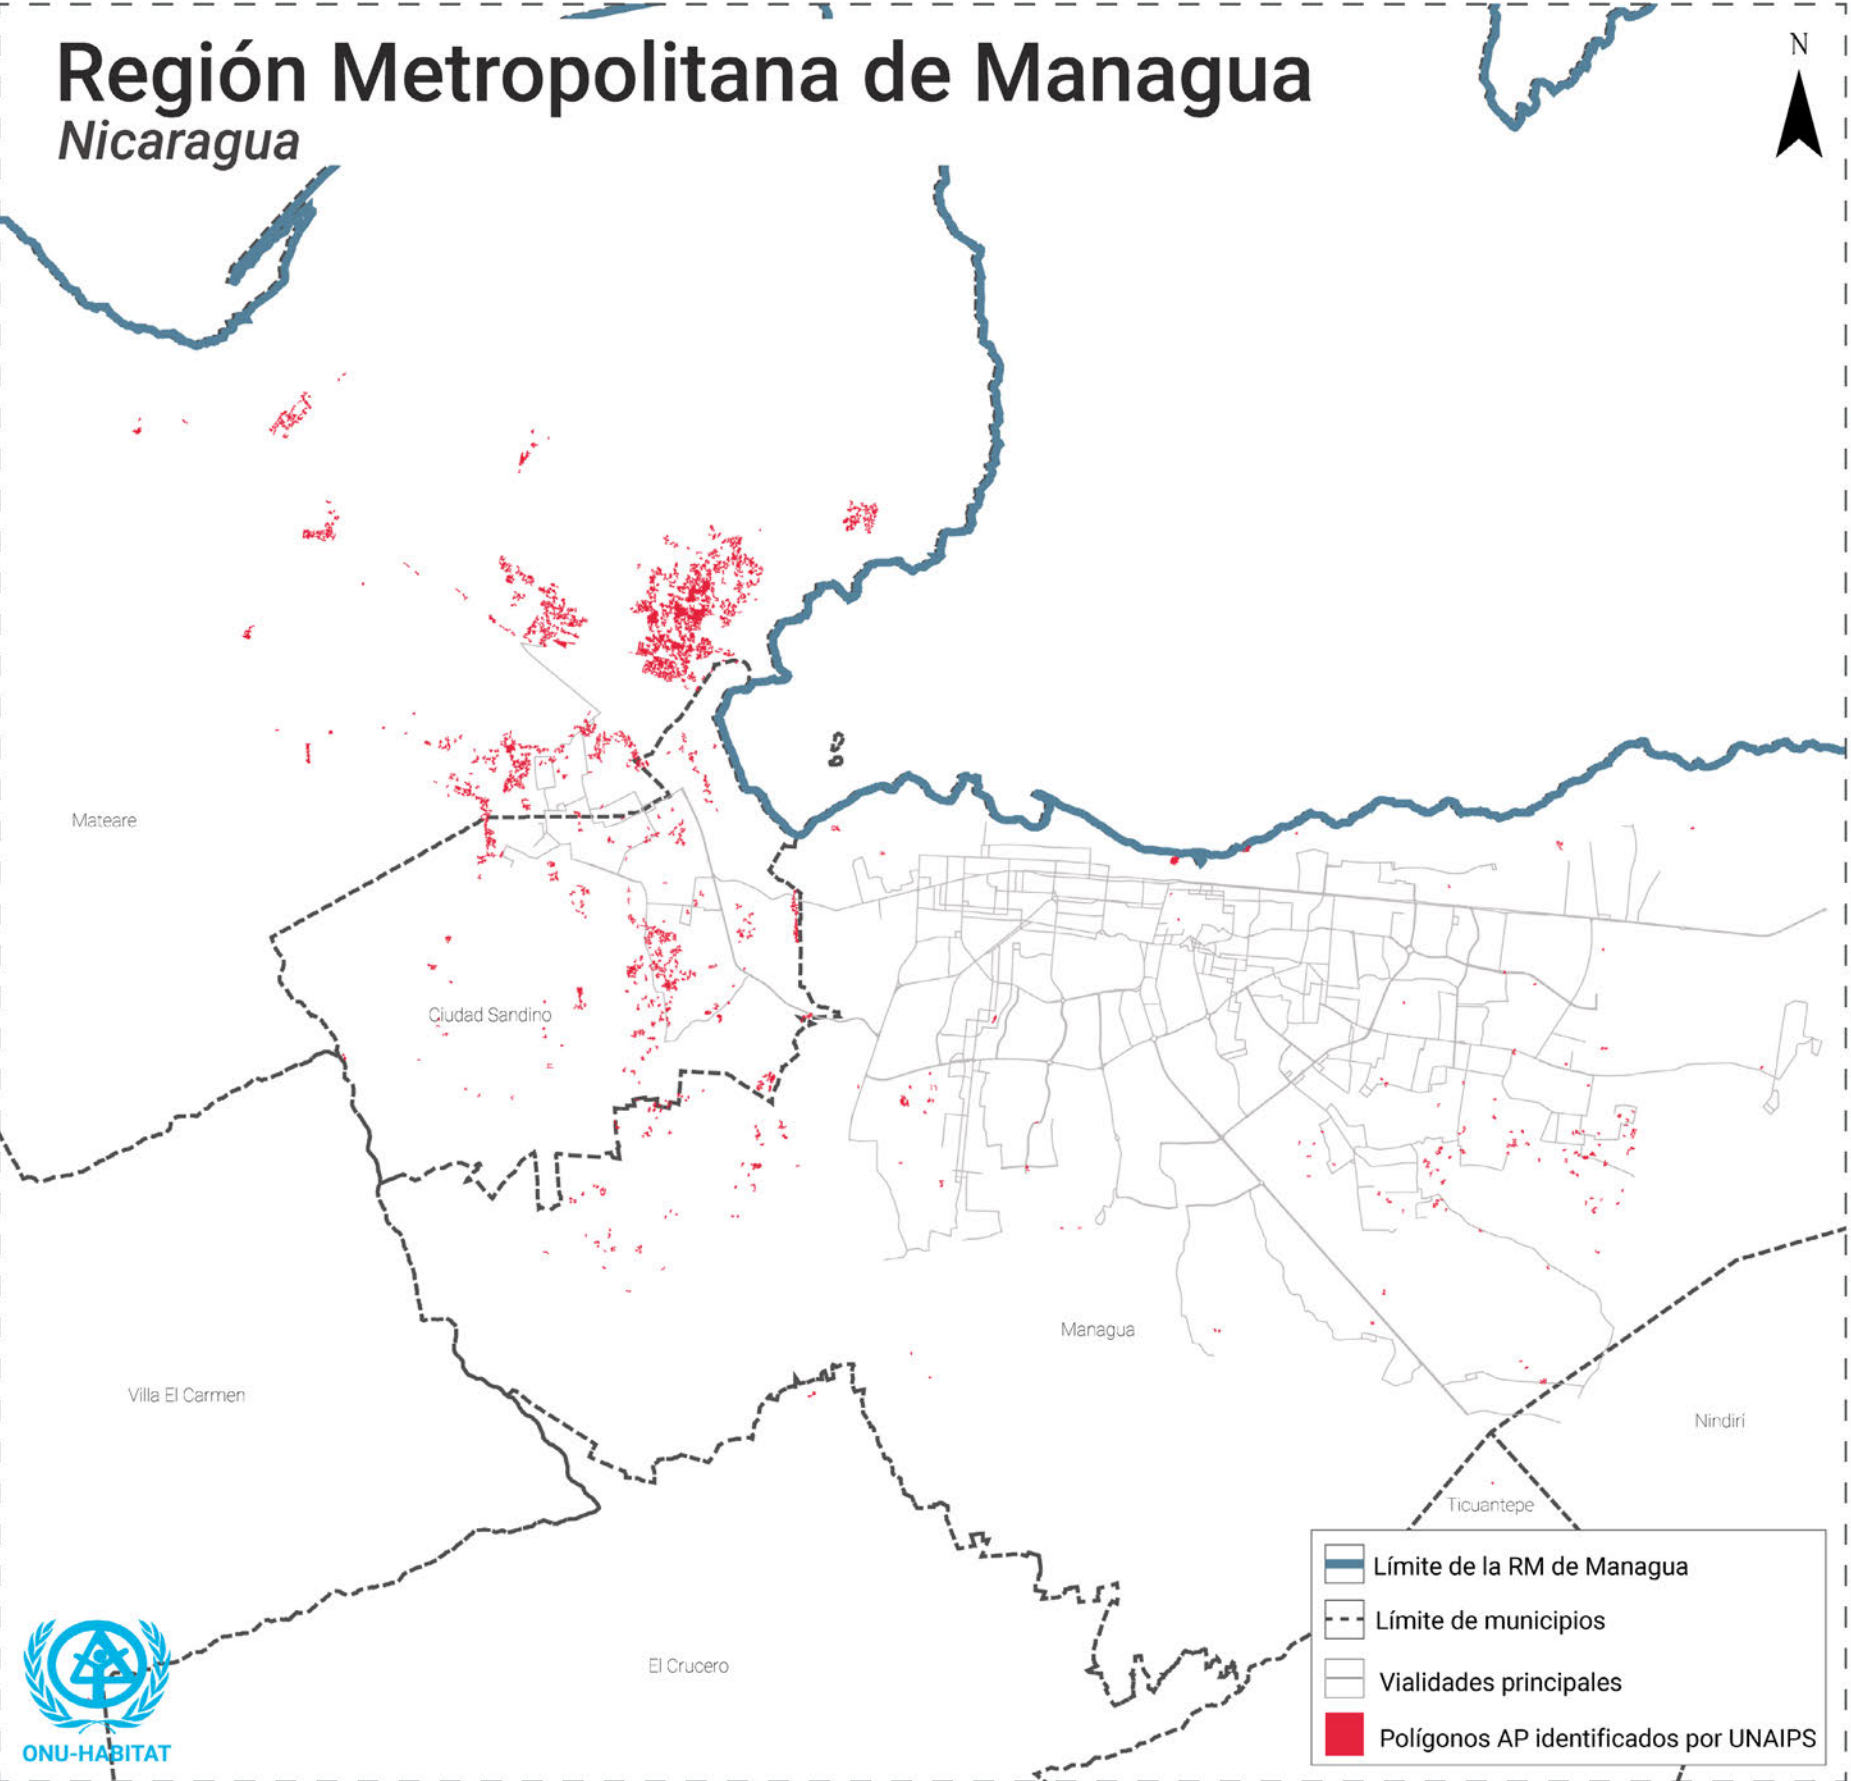


Gráfica 6. Distribución de asentamientos precarios identificados por municipio analizado dentro de la RM de Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.

En cuanto a las características de los asentamientos identificados, se observa que cada asentamiento presenta, en promedio, una superficie de edificaciones de aproximadamente 0.10 hectáreas, según los resultados obtenidos mediante el algoritmo BEAM. Además, se encontró una relación de 0.005 hectáreas entre la superficie total de las edificaciones y el número de techos en el área analizada de la región metropolitana (ver figura 27).






Figura 27. Ejemplo de superficie de techos/edificaciones identificadas en la RM de Managua, Nicaragua.
Fuente: ONU-Habitat, 2024.



La **RM de Managua** presentó **833** polígonos de asentamientos precarios (AP), con una superficie de **320.08 ha**. Los polígonos de **techos** cubren el **25.3%** de los polígonos AP.

Para la generación de los polígonos AP, se utilizaron **imágenes de satélite** WorldView-2, las cuales ofrecieron una cobertura del **15.6 %** con respecto a la **región metropolitana**.



4.7. ÁREA METROPOLITANA DE PANAMÁ

CIUDAD CON ZONAS MARGINALES

A las deficiencias del barrio se le suman las frecuentes deficiencias de su localización, ya que la mayoría se ubican en tierras muy alejadas de los centros urbanos o en parcelas que no son atractivas o apropiadas para el desarrollo formal, tales como riberas de ríos, laderas de cerros o lotes sujetos a contaminación, ruido o inundaciones. (FOBUR 2015)

En esta ciudad, se obtuvieron **852 polígonos** de asentamientos precarios, con una superficie total de 910.66 hectáreas. La identificación y extracción de 37,672 estructuras de techos dentro de los polígonos de AP representan un avance significativo en la detección de características urbanas. Destaca que estas estructuras identificadas cubren el 32.3% de la superficie total de los polígonos AP, como se ejemplifica en la siguiente tabla 8 y se ilustra en la figura 28.

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
AM de Panamá	910.66	294.10	32.3%

Tabla 8. Relación de superficie de polígonos AP y techos para el AM de Panamá.
Fuente: ONU-Habitat, 2024.

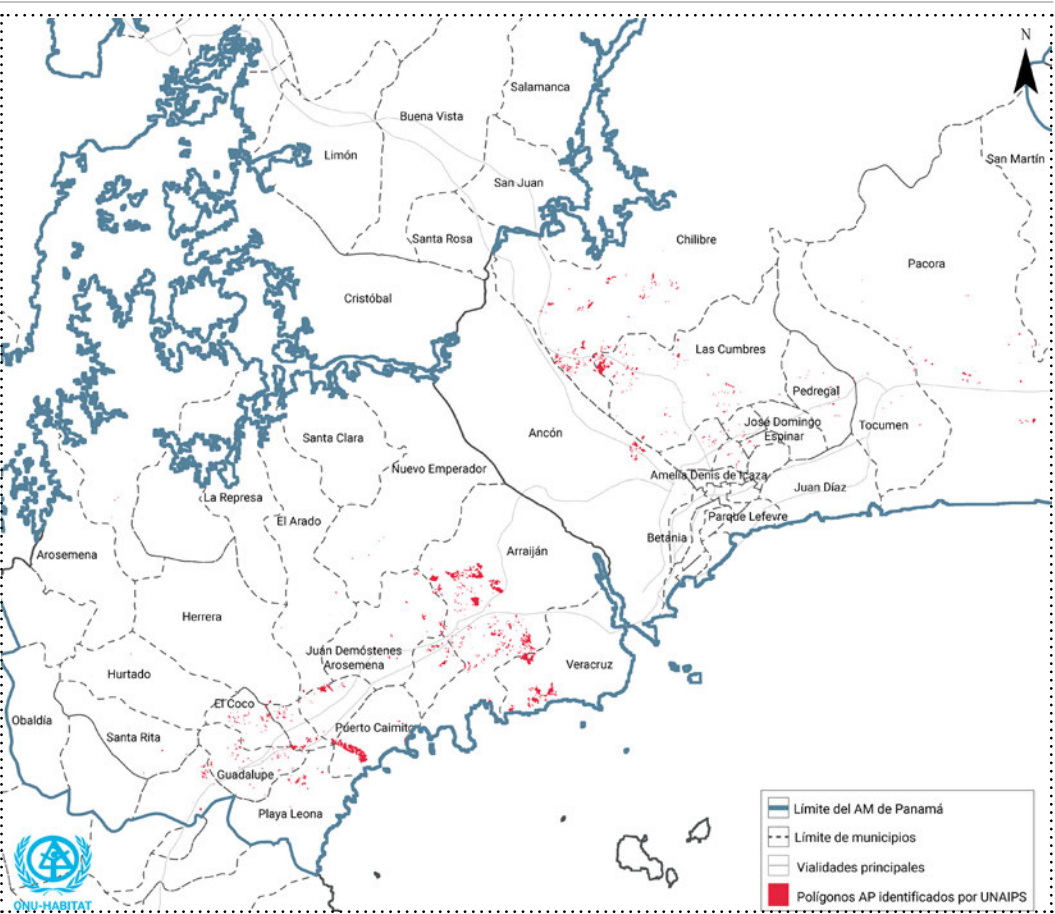



Figura 28. Asentamientos precarios identificados por UNAIPS Methodology en el AM de Panamá.
Fuente: ONU-Habitat, 2024.

La distribución de los polígonos de asentamientos precarios en el AM de Panamá revela que los municipios con la mayor concentración de estos asentamientos son Arraiján, Chilibre, Las Cumbres, El Coco y Guadalupe. Notablemente, estos municipios concentran el 63.2% de los polígonos AP, destacándose con un elevado número de asentamientos precarios, como se muestra en la gráfica 7.


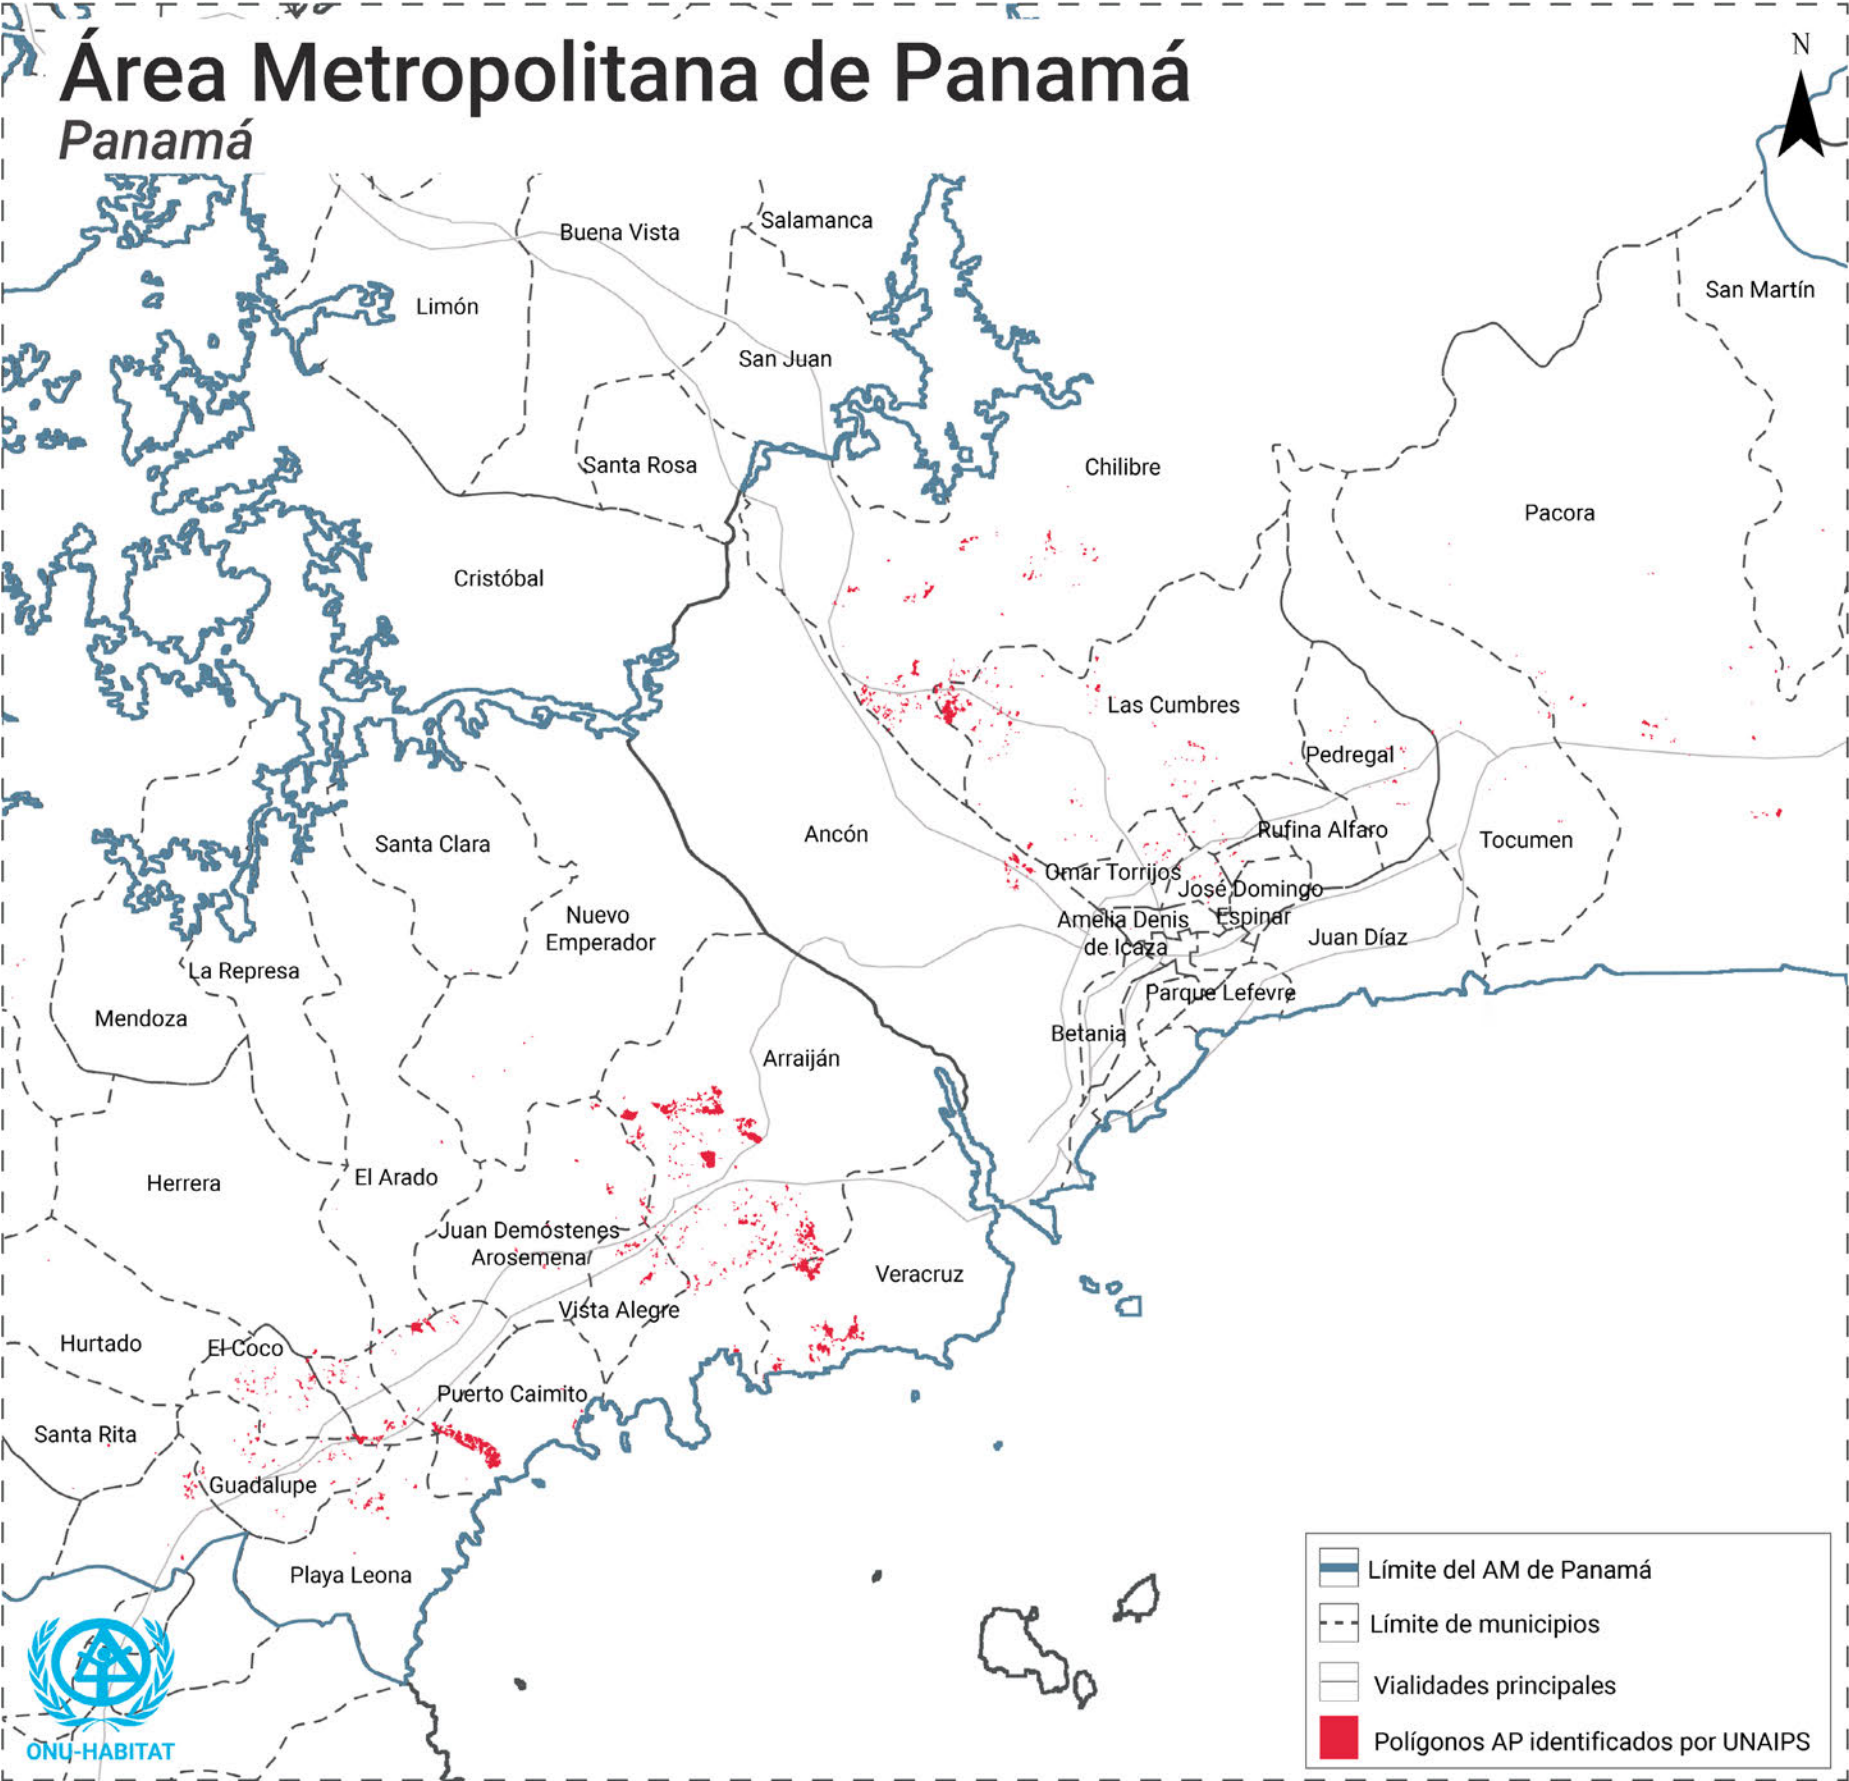


Gráfica 7. Distribución de asentamientos precarios identificados por municipio analizado dentro del AM de Panamá, Panamá.
Fuente: ONU-Habitat, 2024.

En cuanto a las características de los asentamientos identificados, los resultados muestran que, en promedio, cada asentamiento presenta una superficie de edificaciones de aproximadamente 0.35 hectáreas, según los cálculos realizados mediante el algoritmo BEAM. Además, se encontró una relación significativa entre la superficie total de las edificaciones y el número de techos en el área analizada de la región metropolitana, con una proporción de 0.008 hectáreas por techo y una precisión de 0.83 (ver figura 29).



Figura 29. Ejemplo de superficie de techos/edificaciones identificadas en el AM de Panamá, Panamá.
Fuente: ONU-Habitat, 2024.



4.8. ZONA METROPOLITANA DE SANTO DOMINGO

CIUDAD QUE BUSCA LA SOSTENIBILIDAD

Para muchos, los barrios representan la forma más prolífica de la precariedad urbana, la antítesis del ideal urbano dominicano y el principal freno al desarrollo sostenible de la ciudad de Santo Domingo... Construir la ciudad sostenible implica entonces, readaptar las ciudades existentes e intervenir las zonas urbanas cuyas características no coinciden con los criterios de sostenibilidad. (SOSA 2021)

Para la Zona Metropolitana (ZM) de Santo Domingo, República Dominicana, se identificaron **1,765 polígonos** de asentamientos precarios, que ocupan una superficie total de 491.54 hectáreas. Además, se logró detectar 31,789 estructuras de techos, las cuales representan el 36.5% de la superficie de los polígonos de AP, como se puede ver en la tabla 9 y en la figura 30.

CIUDAD	SUPERFICIE POLÍGONOS AP (HA)	SUPERFICIE DE TECHOS (HA)	PORCENTAJE DE TECHOS CON REFERENCIA AL TOTAL DE LOS POLÍGONOS AP
ZM de Santo Domingo	491.54	179.65	36.5%

Tabla 9. Relación de superficie de polígonos AP y techos para la ZM de Santo Domingo, República Dominicana. Fuente: ONU-Habitat, 2024.

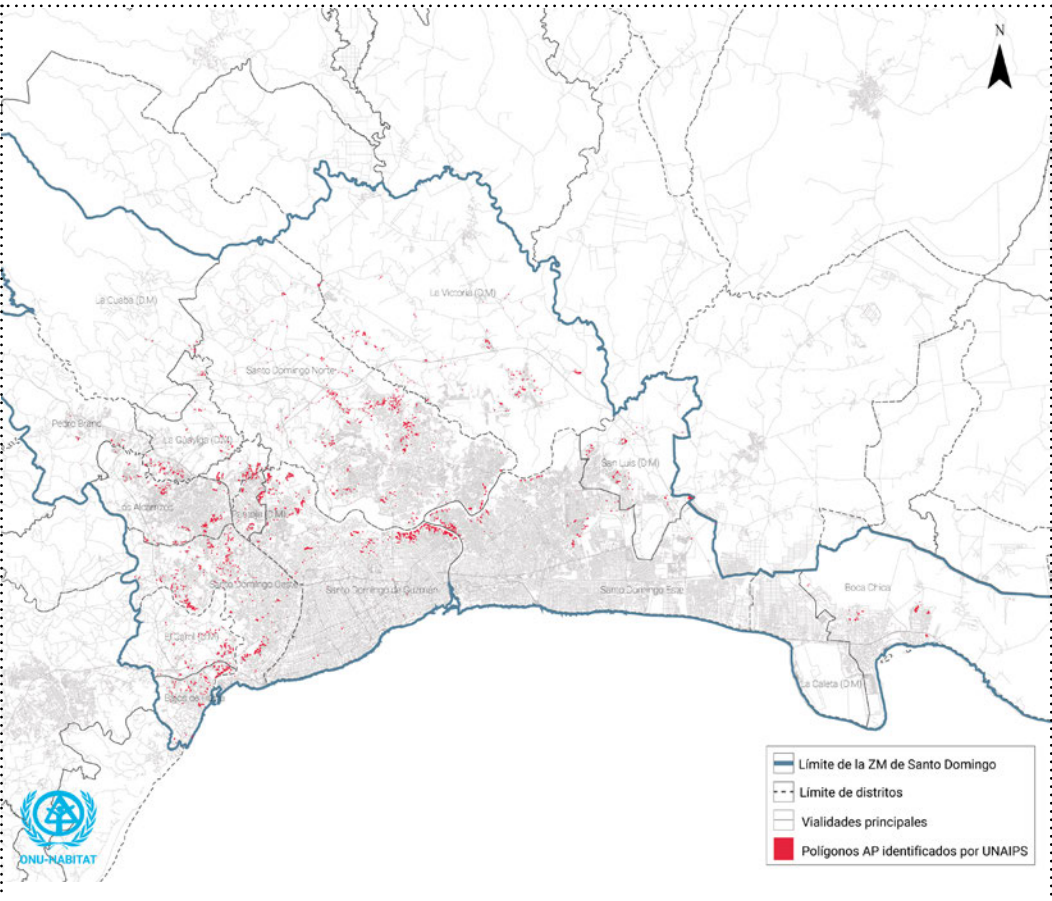



Figura 30. Asentamientos precarios identificados por UNAIPS Methodology en la ZM de Santo Domingo, República Dominicana. Fuente: ONU-Habitat, 2024.

En la zona metropolitana, cinco distritos concentraron la mayor cantidad de asentamientos precarios: Santo Domingo Norte, Santo Domingo de Guzmán, Santo Domingo Oeste, La Victoria (D.M.) y Bajos de Haina. Estos distritos representan un total del 67.3% de los polígonos de asentamiento precarios, tal como se ilustra en la gráfica 8.


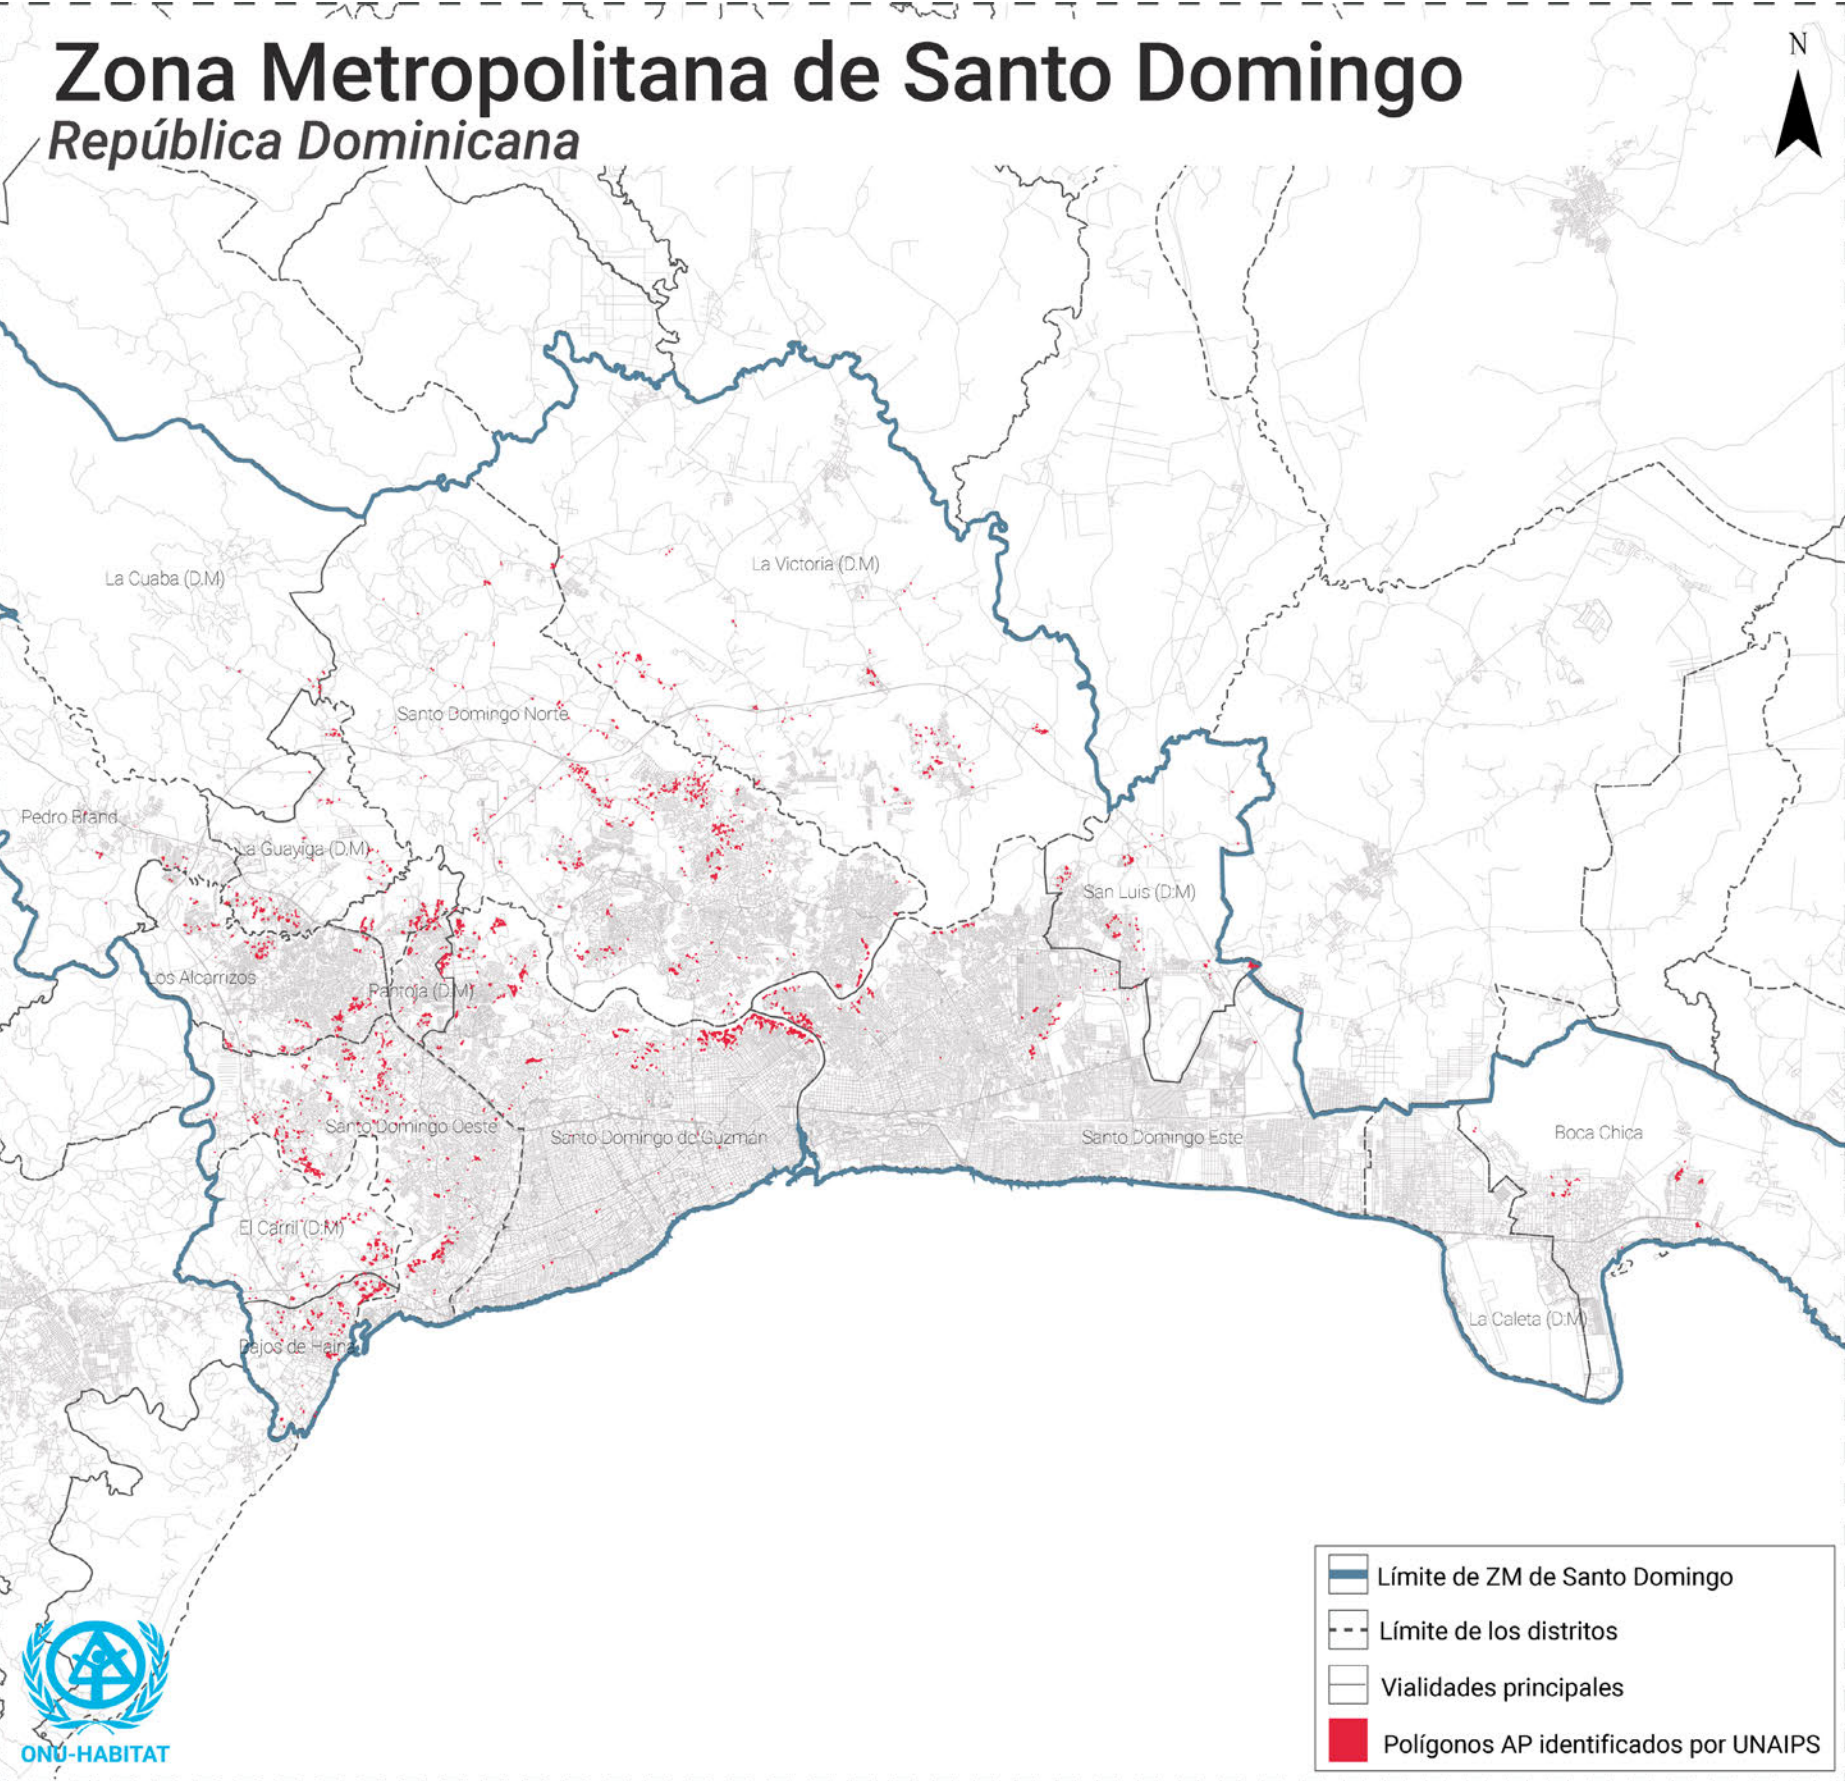


Gráfica 8. Distribución de asentamientos precarios identificados por distrito analizado dentro la ZM de Santo Domingo, República Dominicana. Fuente: ONU-Habitat, 2024.

Las características de estos asentamientos revelan que, en promedio, cada asentamiento identificado tiene una superficie de edificaciones de aproximadamente 0.10 hectáreas, según los cálculos realizados con el algoritmo BEAM. Además, se encontró una relación significativa entre la superficie total de las edificaciones y el número de techos en la ZM de Santo Domingo, con una proporción de 0.006 hectáreas por techo y un nivel de precisión de 0.79. La organización de los techos se puede observar en la figura 31.



Figura 31. Ejemplo de superficie de techos/edificaciones identificadas en la ZM de Santo Domingo, República Dominicana. Fuente: ONU-Habitat, 2024.



5. CONCLUSIONES Y RECOMENDACIONES

A medida que evolucionó este inventario automatizado de asentamientos precarios, se desarrollaron soluciones innovadoras para abordar los desafíos territoriales específicos de las ciudades de Centroamérica y República Dominicana. Entre los primeros desafíos identificados se encontraron la temporalidad de las imágenes y la falta de información socioeconómica detallada sobre las ciudades analizadas. La disponibilidad de imágenes actualizadas fue crucial para reflejar la situación real en el terreno, mientras que la información socioeconómica habría permitido un análisis más profundo y contextualizado de los resultados. En algunos casos, como en Nicaragua, la información disponible correspondía al censo de 1995, mientras que, en otros, como Guatemala y Belice, los datos más recientes databan de 2018 y 2010, respectivamente. Estas discrepancias dificultaron la integración de datos actualizados en el proceso de entrenamiento del algoritmo y limitaron la capacidad de validar los resultados en contextos actuales. Además, la falta de datos detallados sobre los asentamientos precarios en varias ciudades complicó la identificación inicial de zonas de interés, lo que incrementó la dependencia de talleres participativos y validaciones locales. La heterogeneidad en los insumos técnicos también representó un reto significativo.

Desafíos más técnicos, se relacionaron con la operación de herramientas de machine learning en condiciones de hardware limitadas. La mayor parte del desarrollo se realizó de manera remota, utilizando equipos portátiles configurados como servidores con acceso remoto a ellos con características necesarias para el entrenamiento, lo que restringió la capacidad para procesar grandes volúmenes de imágenes satelitales y entrenar modelos complejos. Estas limitaciones técnicas ralentizaron el procesamiento de datos, especialmente en ciudades con un alto volumen de imágenes como Tegucigalpa, donde se analizaron 116 imágenes de alta resolución, y Santo Domingo, con 72 imágenes WorldView-2. Además, no todas las ciudades contaban con imágenes pancromáticas o multispectrales, lo que dificultó la uniformidad en la calidad y tipo de datos disponibles para el análisis.

Otro desafío radicó en las diferencias significativas entre los contextos urbanos y ambientales de cada ciudad. Los materiales constructivos, las condiciones vegetales y los patrones de ocupación de los asentamientos precarios varían ampliamente entre las ciudades estudiadas, lo que obligó durante el proceso de *UNAIPS Methodology* que se generarán entrenamientos de los algoritmos usados de manera específica para cada caso. Por ejemplo, el entrenamiento para San Salvador se benefició de la preidentificación de polígonos de

asentamientos facilitada por las autoridades locales, mientras que otras ciudades, como Belice y Managua, carecieron de estos insumos iniciales. La falta de un modelo único aplicable a todas las ciudades exigió un esfuerzo adicional para ajustar los parámetros del algoritmo y garantizar la precisión en la identificación automatizada de asentamientos.

A pesar de estas limitaciones, se obtuvieron resultados valiosos que ofrecen una visión general importante sobre los asentamientos precarios en las ciudades analizadas. Sin embargo, es importante tener en mente estos aspectos para la actualización de la información en tiempos futuros o para el escalamiento y uso de la herramienta en otros contextos. Aunado a ello, se hace énfasis en la importancia de complementar los resultados obtenidos con la verificación en campo, para completar el ciclo metodológico propuesto y tener un panorama de la precariedad en la región mucho más apegada a lo que existe en el territorio.

Además, este proceso facilitó alianzas estratégicas y trabajo en equipo, lo que permitió un uso óptimo de la tecnología y el intercambio de información tanto dentro de la organización como con las ocho ciudades participantes. Esto resaltó la importancia de involucrar a los gobiernos locales, ya que es fundamental comprender los desafíos únicos que cada ciudad enfrenta en el crecimiento de los asentamientos precarios.

A continuación, se presentan las dos líneas estratégicas principales para el uso óptimo y recomendable del inventario automatizado de asentamientos precarios, con el objetivo de maximizar su potencial y aprovechar al máximo su valor.

5.1. IMPACTO DEL IAAP EN LA REGIÓN SICA

El desarrollo e implementación del IAAP tiene el potencial de generar un impacto transformador en la región SICA, al ofrecer una herramienta avanzada que mejora significativamente la visibilidad y comprensión de los asentamientos precarios. Más que un producto estático, el *UNAIPS Methodology* es una herramienta dinámica que realiza un mapeo preciso, detallado y continuo de las zonas urbanas vulnerables, facilitando una planificación urbana más eficaz y adaptada a las realidades locales.

Además, este proyecto tiene el potencial de fortalecer la cooperación regional en materia de vivienda y desarrollo sostenible, promoviendo la generación de datos estandarizados que permiten realizar análisis comparativos y de tendencias. Esto facilitaría el intercambio de conocimientos y mejores prácticas entre los países miembros, lo que podría mejorar las respuestas coordinadas a desafíos comunes como la vulnerabilidad ante desastres naturales, las deficiencias en infraestructura y los fenómenos migratorios.

De igual forma, al incorporar un enfoque participativo, el IAAP ofrece la posibilidad de empoderar a las comunidades locales, convirtiéndolas en protagonistas clave en la creación de soluciones personalizadas para sus necesidades específicas. Esto no solo mejoraría la eficacia y relevancia de las intervenciones, sino que también garantizaría la sostenibilidad a largo plazo, permitiendo que las comunidades sean auténticos agentes de cambio en su propio desarrollo.

5.2. UNA BASE DE DATOS PARA INFORMAR POLÍTICAS PÚBLICAS EFICACES

En cuanto a políticas públicas, el IAAP ofrece una oportunidad única al proporcionar una base de datos precisa y actualizada en tiempo real. Esta información es fundamental para formular políticas informadas y eficaces en regiones con alto crecimiento urbano. El acceso a estos datos detallados puede tener un impacto transformador directo en la planificación regional, nacional y local, facilitando la identificación de áreas prioritarias, la optimización de recursos y la coordinación de intervenciones de manera más eficiente y estratégica.

De esta manera, la base de datos va más allá de orientar el diseño de estrategias de planificación urbana y territorial, ya que también aborda y puede influir en otras dimensiones clave, como las políticas sociales, económicas, ambientales y productivas. Esto permite una visión integral para abordar de manera más efectiva los diversos desafíos que afectan a los asentamientos vulnerables. Algunas de las áreas clave donde esta herramienta podría tener un impacto significativo son:

a) Políticas de vivienda y asentamientos

- Programas de regularización de tierras: identificación de asentamientos susceptibles de regularización, facilitando procesos de titulación de tierras y garantizando seguridad en la tenencia.
- Mejoramiento de infraestructura en barrios vulnerables: desarrollo de programas de infraestructura básica, como agua potable, electricidad, drenaje y saneamiento en asentamientos precarios.
- Proyectos de vivienda social: orientación sobre la localización de proyectos de vivienda asequible en áreas estratégicas, mejorando la accesibilidad a empleo y servicios básicos.

b) Políticas de desarrollo urbano y ordenamiento territorial

- Planeación urbana integrada: mejora de la planificación territorial mediante la identificación precisa de asentamientos, promoviendo la densificación adecuada y la conectividad urbana.
- Zonificación y uso mixto del suelo: desarrollo de políticas que promuevan el uso mixto del suelo, fomentando la proximidad entre vivienda, comercio, empleo y servicios.
- Revisión de planes urbanos: incorporación de los asentamientos precarios en los planes urbanos existentes, mejorando la planificación en ciudades en rápido crecimiento.

c) Políticas de gestión de riesgos y resiliencia urbana

- Planes de mitigación de desastres: identificación de asentamientos ubicados en zonas de alto riesgo (inundaciones, deslizamientos, terremotos), permitiendo la priorización de medidas de mitigación.
- Programas de reubicación voluntaria: identificación de asentamientos en terrenos no aptos para habitar, facilitando procesos de reubicación con la participación activa de las comunidades afectadas.
- Desarrollo de planes de resiliencia: diseño de políticas para mejorar la capacidad de adaptación al cambio climático, promoviendo soluciones basadas en la naturaleza en asentamientos vulnerables.

d) Políticas de inclusión social y reducción de desigualdad

- Expansión de servicios básicos: identificación de brechas en el acceso a servicios como salud, educación, transporte y seguridad, orientando inversiones hacia áreas desatendidas.
- Generación de empleo y capacitación: diseño de programas laborales que conecten a los residentes de asentamientos precarios con oportunidades de empleo formal y capacitación en sectores estratégicos.
- Fortalecimiento comunitario: desarrollo de iniciativas que fomenten la organización comunitaria, la participación ciudadana y el empoderamiento social, especialmente de grupos vulnerables como mujeres y jóvenes.

e) Políticas ambientales y de protección del territorio

- Sostenibilidad en la urbanización: fomento de políticas que promuevan la conservación ambiental y el uso eficiente de los recursos naturales en zonas urbanas crecientes.
- Estrategias de gestión de residuos: identificación de asentamientos en los que se deben implementar soluciones para la gestión de residuos sólidos, favoreciendo la sostenibilidad urbana.

f) Políticas de seguridad y orden público

- Prevención de la violencia y el crimen: información detallada sobre la distribución de asentamientos vulnerables a la violencia, ayudando en el diseño de políticas de seguridad y prevención del crimen.
- Intervenciones en zonas de alta vulnerabilidad social: planificación de acciones integrales para mejorar la seguridad y el bienestar en áreas identificadas como de riesgo.

g) Políticas de transparencia y gobernanza

- Plataformas de datos abiertos: desarrollo de plataformas públicas que proporcionen acceso a la información generada por el IAAP, facilitando la rendición de cuentas y la participación ciudadana.

- Monitoreo de indicadores urbanos: establecimiento de indicadores clave para evaluar el progreso hacia los objetivos de desarrollo sostenible (ods) y la nueva agenda urbana.

h) Políticas de movilidad y accesibilidad

- Conectividad y acceso a transporte: identificación de áreas con baja conectividad y priorización de proyectos de infraestructura de transporte público que mejoren el acceso a servicios y oportunidades de empleo.

i) Políticas de género y cuidados

- Redistribución de trabajos de cuidado: diseño de políticas que reconozcan y redistribuyan las responsabilidades de cuidado no remunerado, buscando una mayor equidad entre géneros y apoyando a los cuidadores principales, frecuentemente mujeres.
- Infraestructura y servicios para el cuidado: desarrollo de espacios públicos, guarderías y centros comunitarios accesibles y adecuados, para apoyar tanto a mujeres como a hombres en la conciliación de la vida laboral y familiar.
- Promoción de la igualdad de género en la planificación urbana: integración de la perspectiva de género en la planificación urbana y territorial, asegurando que las ciudades sean seguras, inclusivas y accesibles para todas las personas, independientemente de su género.
- Empoderamiento económico de mujeres y cuidadoras: diseño de programas que promuevan la inclusión económica de las mujeres y de las personas dedicadas a tareas de cuidado, proporcionándoles capacitación, acceso a empleo y reconocimiento de su rol esencial en la sociedad.



6. REFERENCIAS

REFERENCIAS

- Agencia Española de Cooperación Internacional para el Desarrollo (AECID) (2022). Reflexiones sobre el webinar: El reto de hacer los asentamientos informales parte de las ciudades centroamericanas. Disponible en: <https://intercoonecta.aecid.es/Gestin%20del%20conocimiento/El%20reto%20de%20hacer%20los%20asentamientos%20informales%20parte%20de%20las%20ciudades.pdf>
- Alcaldes y Alcaldesas del Consejo de Alcaldes del Área Metropolitana de San Salvador (COAMSS) y Oficina de Planificación del Área Metropolitana de San Salvador (OPAMSS) (2016). Esquema director, Área Metropolitana de San Salvador. Editor Consejo de Alcaldes, Oficina de Planificación de Área Metropolitana de San Salvador (OPAMSS). 1ª ed. San Salvador, El Salvador. OPAMSS, 2016. Disponible en: <https://opamss.org.sv/wp-content/uploads/2022/04/ResumenED.pdf>
- Alchapar, N., Correa, E. (2015). Reflectancia solar de las envolventes opacas de la ciudad y su efecto sobre las temperaturas urbanas. Informes de la Construcción, 67(540): e112, Disponible en: <http://dx.doi.org/10.3989/ic.14.131>
- Banco Interamericano de Desarrollo (BID) (2019). Plan de Acción “Ciudad de Belice: redescubrir, reconectar”, 2019. Ciudad de Belice, Belice. Programa de Ciudades Emergentes y Sostenibles (CES). Disponible en: <https://www.iadb.org/es/desarrollo-urbano-y-vivienda/programa-de-ciudades-emergentes-y-sostenibles>
- Comisión Económica para América Latina y el Caribe (CEPAL) (2012). Población, Territorio y Desarrollo Sostenible. Ecuador 2012. Disponible en: <https://www.cepal.org/sites/default/files/events/files/2012-96-poblacion-web.pdf>
- División de Evaluación Social de Inversiones (DESI) (2022). Manual de escalas para la estimación del índice de riesgo de desastres de amenaza por remoción en masa por flujos. Ministerio de Desarrollo Social y Familiar. Gobierno de Chile. Septiembre 2022. Disponible en: https://sni.gob.cl/storage/docs/Manual_de_escalas_IRD_amenaza_por_Remocion_en_masa_-sep2022.pdf
- Foro y Observatorio Urbano de Panamá (FOBUR) (2015). Informe de Investigación No. 1. Los asentamientos informales en el Área Metropolitana de Panamá. Cuantificación e implicaciones para la política de vivienda y urbanismo. Disponible en: <https://usma.ac.pa/wp-content/uploads/2022/09/2015-FOBUR-Informe-1-Vivienda-informal.pdf>
- FUNDASAL y PNUD (2009). Escenarios de vida desde la exclusión urbana. Una mirada al hábitat popular de 32 ciudades de El Salvador. San Salvador. Disponible en: http://repo.fundasal.org.sv/9/1/exclusionurbana_habitat_32ciudades_ElSalvador.pdf
- Gobierno de la República de Guatemala (2017). Política para el mejoramiento integral de Barrios. Hacia la transformación de asentamientos precarios a barrios consolidados y de viviendas dignas, seguras y saludables. Guatemala 2017 – 2032. Disponible en: https://ecursos.segeplan.gob.gt/CAPP/documentos/79/Pol%C3%ADtica_mejoramiento_integral_de_barrios.pdf

- Ministerio de vivienda y asentamientos humanos (MVAH) (2005). Informe sobre las actualizaciones de los asentamientos en precario y en tugurio del Gran Área Metropolitana. San José, Costa Rica, febrero 2005. Disponible en: https://www.mivah.go.cr/Documentos/precarios/Precario_Tugurio_GAM_Febrero_2005/Asentamientos_en_Precario_y_Tugurio_GAM_Febrero_2005.pdf
- Morales, I. y Bernal, D. (2020). Asentamientos Informales en América Latina: Impacto en la Salud Pública. Revista Enfoque. Vol. XXVI No. 22. Panamá. Enero -Junio 2020. Disponible en: <https://revistas.up.ac.pa/index.php/enfoque/article/download/2153/2014/3631>
- María, A., Acero, J. L., Aquilera, A. I. y García, M. (eds) (2018). Estudio de la Urbanización en Centroamérica. Oportunidades de una Centroamérica Urbana. Grupo Banco Mundial, 2018. Disponible en: <https://documents1.worldbank.org/curated/zh/811611517808775995/pdf/Central-America-urbanization-review-making-cities-work-for-Central-America.pdf>
- ONU-Habitat (2015). Temas Habitat III. 22 – Asentamientos Informales. Nueva York, 29 de mayo de 2015. Disponible en: https://habitat3.org/wp-content/uploads/Issue-Paper-22_ASENTAMIENTOS-INFORMALES-SP.pdf
- ONU-Habitat (2023). Caja de herramientas para la mejora de los asentamientos precarios en Centroamérica y República Dominicana. Disponible en: <https://publicacionesonuhabitat.org/onuhabitatmexico/Caja-de-herramientas-para-la-mejora-de-los-asentamientos-precarios-en%20Centroam%C3%A9rica-y-Rep%C3%BAblica-Dominicana.pdf>
- Programa de las Naciones Unidas para el Desarrollo (PNUD) (2009). Propuesta para un programa de pobreza urbana en El Salvador. Disponible en: https://www.undp.org/sites/g/files/zskgke326/files/migration/sv/Propuesta_de_Programa_Pobreza_Urbana_El_Salvador.pdf
- SISCA, LAC Lincoln y GIZ (2023). Glosario Terminológico Anotado (GTA) sobre Asentamientos Informales, Vivienda, Resiliencia Urbana y Gestión del Riesgo. Primera edición Octubre 2023. Disponible en: <https://sisca.int/centro-de-documentacion/resiliencia-urbana/hojas-informativas/glosario-terminologico-annotado-sobre-asentamientos-informales-vivienda-resiliencia-urbana-y-gestion-del-riesgo-gta/1562-glosario-terminologico-annotado-gta-sobre-asentamientos-informales-vivienda-resiliencia-urbana-y-gestion-del-riesgo>
- SOSA Valdez, Darysleida (2021). De precarios a ecológicos y viceversa. Análisis de intervenciones urbanas en asentamientos precarios dominicanos. Revista Estudios Sociales, Vol. XLIV. Pp. 135-162.
- TECHO-Nicaragua. Universidad Centroamericana (UCA) (2015). Censo de asentamientos del Pacífico Urbano de Nicaragua. Disponible en: <https://nicaragua.unfpa.org/sites/default/files/pub-pdf/Informe-Pac%C3%ADfico-Final-24.04.2015-1.pdf>
- Urban Housing Practitioners Hub (UHPH) (s. f.). Programa de Mejoramiento Integral de Asentamientos Precarios Urbanos El Salvador. Disponible en: <https://www.uhph.org/es/concurso/ganadores/programa-de-mejoramiento-integral-de-asentamientos-precarios-urbanos>

- UHPH, et. al. (2020). Laboratorios de Viviedna (LAVs): Asentamientos precarios y vivienda social: Impactos del covid 19 y respuestas. Disponible en: https://www.uhph.org/sites/default/files/2020-11/lav_covid-10_y_asentamientos_sisca.pdf
- UN-Habitat (2003), The Challenge of Slums - Global Report on Human Settlements 2003. Disponible en: <https://unhabitat.org/sites/default/files/download-manager-files/The%20Challenge%20of%20Slums%20-%20Global%20Report%20on%20Human%20Settlements%202003.pdf>
- U.S. Geological Survey (USGS) (2024). U.S. Department of the Interior. Disponible en: <https://earthexplorer.usgs.gov/>



7. ANEXOS

7.1. DETALLES TÉCNICOS DEL UNAIPS METHODOLOGY.

Detección y Análisis de Imágenes Raster

1. Importaciones de Módulos Estándar y Utilidades:

- `os` , `glob` : Para operaciones con el sistema de archivos y buscar archivos.
- `gc` : Manejo de la recolección de basura.
- `pathlib.Path` : Gestión orientada a objetos de rutas y archivos.
- `subprocess.check_output` : Ejecución de comandos y captura de su salida.

2. Librerías Externas para Procesamiento de Imágenes y Deep Learning:

- `albumentations as A` : Aplicación de transformaciones y aumentos en imágenes.
- `torch` : Manejo de tensores y construcción de modelos de aprendizaje profundo.
- `rasterio` : Lectura y escritura de datos raster (imágenes geoespaciales).
- `matplotlib.pyplot as plt` : Visualización de gráficos e imágenes.

3. Componentes de Raster Vision para Segmentación Semántica:

- De `rastervision.core.data` se importan:
 - `RasterioSource` : Lectura de datos raster.
 - `MinMaxTransformer` : Ajuste de valores mediante transformación de rangos.
 - `ClassConfig` y `SemanticSegmentationLabels` : Configuración y gestión de etiquetas en segmentación semántica.
- De `rastervision.pytorch_learner` se importan:
 - `SemanticSegmentationSlidingWindowGeoDataset` : Conjunto de datos basado en ventanas deslizantes para segmentación geoespacial.
 - `SemanticSegmentationLearner` : Clase que facilita el entrenamiento de modelos de segmentación.
- De `rastervision.core.data.label_store.semantic_segmentation_label_store_config` se importa:
 - `PolygonVectorOutputConfig` : Configuración para la salida de polígonos vectoriales a partir de la segmentación.

```
In [ ]: import os
import glob
import gc
from pathlib import Path
from subprocess import check_output

import albumentations as A
import torch
import rasterio
from matplotlib import pyplot as plt

from rastervision.core.data import (
    RasterioSource, MinMaxTransformer, ClassConfig, SemanticSegmentationLabels
)
from rastervision.pytorch_learner import (
    SemanticSegmentationSlidingWindowGeoDataset, SemanticSegmentationLearner
)
from rastervision.core.data.label_store.semantic_segmentation_label_store_config import PolygonVectorOutputConfig
```

1. Configuración de Variables Globales:

- `window_size = 256` : Define el tamaño de la ventana para procesamiento o segmentación.
- `model_folder = "./model/"` : Directorio donde se encuentra el modelo.
- `model_file = model_folder + "model-bundle-ss.zip"` : Ruta completa del archivo que contiene el modelo.
- `save_dir = "./results/"` : Directorio para guardar los resultados.

2. Cargar Archivos Raster:

- `raster_path = "./detect/*.tif"` : Especifica el patrón de búsqueda para archivos `.tif` en la carpeta `./detect/`.
- `raster_files = glob.glob(raster_path)` : Obtiene una lista de archivos que coinciden con el patrón `raster_path`.
- La última línea imprime o devuelve la lista de archivos raster encontrados.

```
In [ ]: window_size = 256
model_folder = "./model/"
model_file = model_folder + "model-bundle-ss.zip"
save_dir = "./results/"

raster_path = "./detect/*.tif"
raster_files = glob.glob(raster_path)
raster_files
```


1. Verificación de Disponibilidad de CUDA:

- `print(f"CUDA disponible: {torch.cuda.is_available()}")`
Muestra si CUDA está disponible para acelerar el procesamiento mediante GPUs.
- `print(f"Número de dispositivos CUDA: {torch.cuda.device_count()}")`
Imprime el número de dispositivos CUDA disponibles.

2. Creación del Objeto RasterioSource:

- `raster_source = RasterioSource(raster_files, allow_streaming=True)`
Se crea una instancia de RasterioSource usando la lista de archivos raster. El parámetro `allow_streaming=True` permite leer las imágenes en forma de stream, útil para imágenes grandes o cuando se quiere minimizar el uso de memoria.

3. Visualización de la Dimensión de los Datos Raster:

- `print(raster_source.shape)`
Imprime la forma (shape) de los datos cargados, lo que generalmente indica dimensiones o características relevantes del raster.

```
In [ ]: # Verificar disponibilidad de CUDA
print(f"CUDA disponible: {torch.cuda.is_available()}")
print(f"Número de dispositivos CUDA: {torch.cuda.device_count()}")

raster_source = RasterioSource(raster_files, allow_streaming=True)
print(raster_source.shape)
```

1. Definición de la Configuración de Clases:

- `class_config = ClassConfig(...)`
Configura las clases para segmentación semántica, definiendo:
 - `names` : Lista de nombres de clases, en este caso `'background'` y `'asentamiento'`.
 - `colors` : Colores asignados a cada clase (por ejemplo, `'black'` para el fondo y `'orange'` para asentamientos).
 - `null_class` : Indica cuál es la clase a tratar como fondo o sin etiqueta, aquí definida como `'background'`.

2. Configuración de Transformaciones y Aumentación de Datos:

- `data_augmentation_transform = A.Compose([...])`
Define una cadena de transformaciones que se aplicarán a las imágenes para aumentar la variedad de datos.
 - Se aplican operaciones de flipping y de transformación geométrica (`A.Flip()`, `A.ShiftScaleRotate()`).
 - Se utiliza `A.OneOf([...])` para aplicar de forma aleatoria una de varias transformaciones de color y brillo (e.g., cambios en tono, saturación, conversión a escala de grises, sepia, contraste y gamma).
 - Finalmente, se aplica `A.CoarseDropout(...)` para eliminar porciones de la imagen de forma aleatoria, ayudando a reducir el sobreajuste.

```
In [4]: class_config = ClassConfig(
names=['background', 'asentamiento'],
colors=['black', 'orange'],
null_class='background'
)

data_augmentation_transform = A.Compose([
A.Flip(),
A.ShiftScaleRotate(),
A.OneOf([
A.HueSaturationValue(hue_shift_limit=10),
A.RGBShift(),
A.ToGray(),
A.ToSepia(),
A.RandomBrightnessContrast(),
A.RandomGamma(),
]),
A.CoarseDropout(max_height=int(window_size/6), max_width=int(window_size/6), max_holes=4)
])
```

1. Carga del Modelo:

- Se utiliza `torch.hub.load` para descargar y cargar un modelo FPN (Feature Pyramid Network) basado en ResNet50 desde el repositorio `AdeeLH/pytorch-fpn` (versión 0.3).
- Parámetros configurados:
 - `fpn_type='panoptic'` : Se usa una variante panóptica de FPN.

- `num_classes=len(class_config)` : Se ajusta el número de clases para segmentación según la configuración definida.
- `fpn_channels=256, in_channels=3` : Configuración de canales de entrada y del FPN.
- `out_size=(window_size, window_size)` : Tamaño de salida de la imagen.
- `pretrained=True` : Se carga un modelo preentrenado.

2. Inicialización del Learner de Segmentación Semántica:

- Se crea una instancia de `SemanticSegmentationLearner` a partir de un bundle de modelo:
 - `model_bundle_uri=model_file` : Ubicación del bundle del modelo.
 - `model=model` : El modelo cargado previamente.
 - `output_dir=model_folder` : Directorio para salida del modelo.
 - `training=False` : Se establece en falso indicando que el modelo se usará para inferencia, no para entrenamiento.

```
In [ ]: model = torch.hub.load(
'AdeeLH/pytorch-fpn:0.3',
'make_fpn_resnet',
name='resnet50',
fpn_type='panoptic',
num_classes=len(class_config),
fpn_channels=256,
in_channels=3,
out_size=(window_size, window_size),
pretrained=True
)

learner = SemanticSegmentationLearner.from_model_bundle(
model_bundle_uri=model_file,
model=model,
output_dir=model_folder,
training=False
)
```

1. Definición y Propósito de la Función

- Se define la función `generate_prediction_polygons` que procesa una imagen raster para generar las predicciones en forma de polígonos vectoriales.
- Parámetros:
 - `raster_file` : Ruta del archivo raster a procesar.
 - `class_config` : Configuración de las clases de segmentación.
 - `learner` : Objeto encargado de realizar la predicción (modelo de segmentación).
 - `save_dir` : Directorio donde se guardarán los resultados.

2. Procesamiento y Predicción

- Se imprime un mensaje indicando el inicio del proceso para el archivo.
- Dentro del bloque `try` :
 - Se crea un objeto `RasterioSource`, el cual abre el archivo raster con `allow_streaming=True` y aplica un `MinMaxTransformer` para normalizar los valores.
 - Se genera un dataset de inferencia mediante `SemanticSegmentationSlidingWindowGeoDataset.from_uris`, configurando el tamaño de ventana (`window_size`) y un `stride` basado en un tercio del tamaño.
 - Se obtienen las predicciones con `learner.predict_dataset`, configurando la salida para que tenga el mismo tamaño que la ventana y utilizando un progress bar.

3. Post-procesamiento de Predicciones

- Las predicciones se convierten en etiquetas semánticas usando `SemanticSegmentationLabels.from_predictions`.
 - Se aplica suavizado y se utiliza la extensión de la escena del dataset.
 - Se especifica el número de clases mediante `len(class_config)`.
- Se guardan las etiquetas en disco (salida vectorial) utilizando la función `save` y se configura la salida de los polígonos (para la clase con id 1) mediante `PolygonVectorOutputConfig`.

4. Renombrado y Manejo de Errores

- Se renombra el archivo de predicción generado para utilizar el nombre base del archivo raster.
- En caso de error durante el proceso, se captura y se imprime un mensaje con la descripción del error.
- Finalmente, se realiza una limpieza de memoria con `gc.collect()` para liberar recursos.

```
In [6]: def generate_prediction_polygons(raster_file, class_config, learner, save_dir):

print(f'Procesando {raster_file}...')
```



```
try:
    img_raster_source = RasterioSource(raster_file, allow_streaming=True, raster_transformers=[MinMaxTransforme

    pred_ds = SemanticSegmentationSlidingWindowGeoDataset.from_uris(
        class_config=class_config,
        image_uri=raster_file,
        image_raster_source_kw=dict(allow_streaming=True),
        size=window_size,
        stride=window_size // 3
    )

    predictions = learner.predict_dataset(
        pred_ds,
        raw_out=True,
        numpy_out=True,
        predict_kw=dict(out_shape=(window_size, window_size)),
        progress_bar=True
    )

    pred_labels = SemanticSegmentationLabels.from_predictions(
        pred_ds.windows,
        predictions,
        smooth=True,
        extent=pred_ds.scene.extent,
        num_classes=len(class_config)
    )

    pred_labels.save(
        uri=save_dir,
        crs_transformer=img_raster_source.crs_transformer,
        class_config=class_config,
        discrete_output=False,
        smooth_output=False,
        smooth_as_uint8=True,
        vector_outputs=[PolygonVectorOutputConfig(class_id=1)]
    )

    output_file = Path(save_dir) / "vector_output" / f"{Path(raster_file).stem}_prediction.json"
    (Path(save_dir) / "vector_output" / "class-1-asentamiento.json").rename(output_file)

    print(f'Completado: {raster_file}\n')

except Exception as e:
    print(f"Error procesando {raster_file}: {str(e)}")

finally:
    gc.collect()
```

1. Se itera sobre cada archivo en la lista `raster_files`.
- Para cada `raster_file`, se llama a la función `generate_prediction_polygons` pasando:
 - El archivo raster actual (`raster_file`).
 - La configuración de clases (`class_config`).
 - El objeto `learner` que realiza las predicciones.
 - El directorio de salida (`save_dir`).
 - Esto permite procesar y generar las predicciones en forma de polígonos para cada imagen en el conjunto.

```
In [ ]: for raster_file in raster_files:
        generate_prediction_polygons(raster_file, class_config, learner, save_dir)
```

7.2. DETALLES TÉCNICOS DEL ALGORITMO BEAM.

BEAM Model Training Technical Documentation

14th March 2024
Author: Nathan Kiner (Data Science Consultant @ UNITAC)



INTRODUCTION.....3

CLASS COMPONENTS3

 DataTiler.....3

 Configuration and Initialization3

 Key Methods4

 Private methods.....4

 Usage Example5

 Expected Output.....5

 Trainer6

 Configuration and initialization6

Key Methods.....	7
Private Methods.....	7
Usage Example	8
Expected Output.....	8
MapGenerator	9
Initialization and configuration	9
Key Methods.....	10
Private methods.....	10
Usage Example	10
Expected Output.....	11
Class Module: Evaluator	11
Configuration and Initialization	11
Key Methods.....	12
Private Methods.....	12
Usage Example	13
Expected Outputs.....	13
BaseClass	13
Initialization	13
Key Methods.....	14
FUNCTIONAL COMPONENTS	14
Transform.....	14
Key Functions	14
Usage Example	15
Expected Outputs.....	15
Sample	16
Key Functions	16
Expected Outputs.....	17
Usage Scenarios	17
Example Usage	17
Module: Losses.....	18
Loss Functions.....	18
Helpers	19
	2

Key functions	19
---------------------	----

INTRODUCTION

The present document provides a clear guide to the codebase, breaking down the different code components, classes, and modules that make up the BEAM model development project. Each part of the API is explained in simple terms, showing what it does and how it fits into the overall system.

For each public function and method, we will list the parameters you need to provide, what you'll get back, and any example commands to show how it's used. This makes it easier to use the system without having to look through the source code for basic information. When it's helpful, we also show how different parts of the code are connected, giving you a picture of how the system is put together.

This documentation is here to help users and developers of the codebase quickly find how to use the system for their needs, add new features, or improve existing ones.

CLASS COMPONENTS

DataTiler

The `DataTiler` class, inheriting from `BaseClass`, is designed for processing geospatial imagery and the associated label data into smaller, manageable tiles. This processing step must be done before the machine learning training procedure, which will iterate over tiles to iteratively update the weights of the model and improve its ability to detect buildings in informal settlements. The class facilitates the loading of images and optional label data, generating binary masks and weight tiles if required, and saving these tiles for further processing.

Configuration and Initialization

To initialize a `DataTiler` object, the following arguments are required:

- `project_dir`: A string specifying the path to the project directory. This directory should contain the images, a configuration file, and optionally, label files if it's a training project.
- `config_name`: The configuration file name. If missing, the constructor will look for a single file in the project directory.

The configuration file must specify the following attributes:

- `seed`: A seed value for ensuring reproducibility in operations that involve randomness.
- `tiling_params`: A dictionary containing parameters related to the tiling process. It includes:

- **distance_weighting**: A boolean indicating whether to apply distance weighting to the tiles, generating weight files for each tile alongside its mask.
- **erosion**: A boolean indicating whether to apply erosion to the mask tiles, which can help in certain segmentation tasks by reducing the size of the detected objects slightly.
- **tile_size**: An integer specifying the size (height and width) of the square tiles to be generated.

In addition, the project directory should contain the following elements:

- **images/** directory: All the images selected to cover the area of interest, with the type of imagery that will be used to detect the buildings and generate the final shapefiles. The images are expected to be in the TIFF format, and can, depending of the nature of the imagery, entail 8 channels (Worldview-3 imagery), 4 channels (aerial images) or 3 channels (standard RGB image).
- **labels/** directory: *(optional)* What will be used as ground truth labels, in the training scenario. The nature of the labels can vary depending on whether the run is for pre-training, fine-tuning, or for other experiments, but will always outline what the model considers to be buildings - the **ground truth** - in relation to the imagery selected. The accepted format are:
 - **Shapefile (.shp)** along with all its associated files.
 - **CSV file (.csv or .csv.gz)** containing geometries in WKT format, in the CRS EPSG:4326 (Google Open Buildings format).

Key Methods

- **generate_tiles(self, tile_size=0, write_tmp_files=False)**: Segments both images and masks into tiles and stores them as TIFF files in their respective directories. If distance weighting is enabled, weight tiles are also generated and stored.
- **generate_mask(self, image, labels, write=False)**: Generates a binary mask from vector labels. Optionally, it also writes the mask (and weights, if distance weighting is applied) to disk.

Private methods

- **_load_tiling_params(self, config)**: Extracts tiling parameters from the provided configuration dictionary.
- **_load_images(self, image_dir)**: Loads all GeoTIFF images from the specified directory, yielding each as an `xarray.DataArray`.
- **_load_labels(self, labels_files)**: Loads building footprints from vector files (CSV, SHP, or compressed CSV) into a `GeoDataFrame`.

- **_crop_labels(self, image)**: Crops label data to the bounding box of a given input image.
- **_write_da_to_raster(self, data, name, directory)**: Writes a given `xarray.DataArray` to a raster file in GeoTIFF format.

Usage Example

```
from preprocess.data_tiler import DataTiler

# Path to your project directory and name of your config file
project_dir = "/path/to/your/project"

config_name = "project_config.yaml"

# Initialize the DataTiler
img_tiler = DataTiler(project_dir, config_name)

# Generate tiles with the specified tile size
tile_size = 256

img_tiler.generate_tiles(tile_size)
```

Expected Output

Tiles are saved in subdirectories within the project directory:

- **image_tiles**: Contains the image tiles.
- **mask_tiles**: Contains the mask tiles, if labels were provided.
- **weight_tiles**: Contains the weight tiles, if `distance_weighting` was enabled.

The tiles are all saved in TIFF format, preserving the geospatial position of the tile throughout the pipeline. Names are derived from the original file name, with the added suffix `_[row_number]_[column_number]` to display the row and column of a tile relative to its parent image. This modular approach allows for flexible preprocessing of satellite imagery and labels,

facilitating the training of the BEAM model and the generation of maps with accurate geographic coordinates.

Trainer

The `Trainer` class is designed to facilitate the setup and execution of the training process for the segmentation models. It is responsible for configuring the training environment, initializing data transformations, preparing data loaders, and executing the training runs. The class supports the U-Net and HRNet architectures and offers customization options through configuration parameters.

Configuration and initialization

Constructor arguments:

- `project_dir (str)`: Path to the project directory, which should contain a tiles directory with train and test folders for training data.
- `config_name (str, optional)`: The configuration file name. If missing, the constructor will look for a single file in the project directory. This file contains all necessary settings for training, including model architecture, training parameters, and data augmentation strategies.

The configuration file must contain the following attributes:

- `codes`: A list of strings representing different categories or types in the experiment. For the current scope of the BEAM project this defaults to "Background" and "Building".
- `seed`: An integer value used for random seed setting, ensuring reproducibility.
- `test_size`: The fraction of the dataset used for testing and validation. Must be a number between 0 and 1.
- (optional) `model_version`: If fine-tuning, the name of the model directory to be used as pre-trained model. If missing, the Trainer will look for a single directory in the `base_model/` directory.
- Training parameters:
 - `architecture`: The architecture of the model, e.g., "U-Net".
 - `backbone`: (optional for fine-tuning) The backbone network used, e.g., "resnet18".
 - `epochs`: An integer indicating the number of training epochs, e.g., 30.
 - `loss_function`: (optional for fine-tuning) Specifies the loss function used. It can be a string or None.
 - `early_stopping`: Specifies whether early stopping is applied to the model training.
 - `finetune`: A boolean flag indicating whether the training should be done in pre-training mode or fine-tuning. If true, the pretrained model directory is expected to be found in the `base_model/` sub-directory.
 - `batch_size`: (optional for fine-tuning) The size of the batch being processed before each gradient update. If blank, will default to the best option based on the model architecture.

The expected directory structure for training is as follow:

- `tiles/train/images/`: A directory containing all the image tiles that should be used for training, in TIFF format, reduced to RGB channels. This folder can be created by the `gen_train_test` function of the `transform.py` module.
- `tiles/train/masks/`: A directory containing all the corresponding ground truth tiles that will be used for training, in TIFF format, reduced to a single band, and with names matching the image tile that they correspond with. This folder can be created by the `gen_train_test` function of the `transform.py` module.
- `models/`: A directory to store all models created by the Trainer module. This directory will be created if it does not exist yet when starting the training process.

Key Methods

- `check_dataset_balance(self, sample_size=50)`
Evaluates the balance of the dataset by analyzing the distribution of class pixels across a sample of images, aiding in understanding dataset biases.
- `setup_data_transforms(self)`
Prepares a list of data augmentation transforms to be applied during training, enhancing model generalization and robustness.
- `prepare_data loaders(self, tfms)`
Prepares data loaders for training and validation, applying the specified transformations and partitioning the data for validation based on the test size.
- `run(self)`
Executes the training process based on the configured parameters, applying image augmentations, setting up the model, and running the training for the defined number of epochs, or until progress stalls (early stopping).

Private Methods

- `_load_params(self, config)`
Loads and validates general parameters for training from the configuration file. It checks for essential keys and validates values such as the test size and seed.
- `_load_train_params(self, config)`
Extracts training-specific parameters from the configuration, ensuring the specified architecture is supported and initializing training parameters like epochs, batch size, and loss function.
- `_map_unique_classes(self, is_partial=False)`
Generates a mapping of unique class values from the dataset. This method can operate on a subset of the data to increase efficiency.

- `_get_mask(self, image_path, pixel_to_class)`
Retrieves and adjusts a mask based on the provided image path and pixel-to-class mapping. This method supports the inclusion of distance weighting by stacking the mask with corresponding weights.
- `_get_batch_size(self, tile_size, backbone)`
Determines an appropriate batch size based on the tile size and the selected model backbone, optimizing for memory usage and computational efficiency.
- `_callbacks(self)`
Constructs a list of training callbacks, including logging, visualization, and early stopping mechanisms, to enhance training monitoring and control.
- `get_y(self, x)`
A label function that returns the mask for a given image, facilitating the creation of segmentation data loaders.
- `_save(self)`
Saves the trained model and its parameters to disk, facilitating model deployment and further analysis.

Usage Example

To use the `Trainer` class, you must specify the project directory and optionally the configuration file name. The class then manages the entire training process, from data preparation to model training and saving.

```
from segmentation.train import Trainer

project_dir = 'path/to/project/directory'
config_name = 'project_config.yaml'

trainer = Trainer(project_dir, config_name)

trainer.run()
```

Expected Output

Executing the run function will create a new `models/` sub-directory, in which the learner checkpoint will be saved at the end of the process. Each run will generate a new directory with the following contents:

- `Dataset_balance.png`: Histogram of the class distribution across the dataset.
- `Model_parameters.json`: An export of the configuration parameters used for this particular run.
- `train_metrics.csv`: A table showing the evolution of different metrics tracked during training: train and validation loss, Dice and Jaccard coefficient, as well as time per epoch.

- `[run_id].pkl`: The learner checkpoint, saved after completion of the run.
- `tb_logs`: *(only available for U-Net training)* A directory used for reviewing the results in Tensorboard (see User Manual).

MapGenerator

The `MapGenerator` class is designed to automate the process of generating maps from images using a previously trained segmentation model. This class can be used directly for inference, over a single tile or multiple tiles, and will convert each prediction tile into vector files in the process of inference. It can also be used in a more targeted way, taking a shapefile representing the boundaries of the informal settlements as input, together with a collection of tiles, and will then generate a vector file mapping only the areas covered by polygons in the input shapefile.

Initialization and configuration

Constructor arguments:

- `project_dir (str)`: Path to the project directory, which should contain a `tiles` directory with train and test folders for training data.
- `config_name (str, optional)`: The configuration file name. If missing, the constructor will look for a single file in the project directory. This file contains all necessary settings for training, including model architecture, training parameters, and data augmentation strategies.
- `generate_preds (bool, optional)`: Boolean flag indicating whether the predictions should be generated as part of the map generation, or whether they are already provided in the directory.

For initialization, the `MapGenerator` requires a configuration file (`project_config.yaml` by default) that specifies several critical settings:

- `seed`: A seed value for random number generation to ensure reproducibility.
- `model_version`: Specifies the version of the trained model to use for inference. This model should be pre-loaded in the `models/` sub-directory.
- `tiling`: Contains tiling parameters, including:
 - `erosion`: A boolean indicating whether erosion preprocessing was applied to the training data, which affects how the mask is post-processed.

Expected Project Directory Structure

- `tiles/test/images/`: A directory with the images on which inference will be performed. The module will by default run prediction on this dataset. Another dataset can be passed as an argument to the map generation function.

- `models/`: Contains the trained model files. The specific model used is determined by the `model_version` specified in the configuration file.
- `predictions/` (optional): Directory containing predictions from the model to use to generate the map. If `generate_preds=True`, the module will generate and store the output prediction rasters in this directory.
- `shapefiles/` (optional): As shapefiles get generated from the predictions, they will be saved in this directory.

Key Methods

- `single_tile_inference(image_file, boundaries_gdf=None, write_shp=True)`: Performs inference on a single image tile, optionally assessing spatial inclusion in polygon boundaries, and can write the output directly to a shapefile.
- `create_tile_inferences(image_files, boundaries_gdf=None, write_shp=False, parallel=True)`: Performs inference on a collection of image files and optionally writes the results to shapefiles.
- `generate_map_from_images(images_dir=None, settlements=None, primary_key="")`: Orchestrates the inference process across all tiles in the specified directory, optionally merging results based on settlement boundaries.
- `create_shp_from_mask(images_dir)`: Converts a binary mask `DataArray` into a `GeoDataFrame` of polygons, representing detected buildings or features.
- `get_crs(mask_da)`: Initializes the CRS from a directory of images, assuming the CRS is consistent across the directory.

Private methods

- `_get_image_files(images_dir)`: Retrieve a list of image files from the specified directory.
- `_group_tiles_by_connected_area(mask_tiles, boundaries_gdf, primary_key)`: Organizes tiles by connected areas based on settlement boundaries to facilitate area-specific vectorization.
- `_filter_by_areas(output_files, settlements, primary_key)`: Filters and merges raster predictions by settlement areas, using a primary key to associate predictions with specific settlements.

Usage Example

The `MapGenerator` is instantiated with the path to the project directory, the name of the configuration file, and a flag indicating whether to generate predictions. Once initialized, the `generate_map_from_images` method can be called to start the map generation process, which involves running the model on each image tile, generating predictions, and optionally vectorizing these predictions into shapefiles. The `create_tile_inferences` can be used to generate predictions and shapefiles for a collection of tiles.

```
from segmentation.infer import MapGenerator

project_dir = 'path/to/project/directory'
config_name = 'project_config.yaml'
generate_preds = True

map_gen = MapGenerator(project_dir, config_name, generate_preds)

map_gen.generate_map_from_images()
```

Expected Output

The results of this module will be distributed between two folders:

- `predictions/`: A collection of all the predicted tiles as grayscale TIFF images, requested directly or as intermediary files to generate the final map.
- `shapefiles/`: The vector files generated by the class instance, for each individual tile, for a collection of tiles, or filtered specifically to cover a given area of interest (informal settlement boundaries).

This module can therefore be used either in combination with the `Evaluator` module, providing predictions to be compared with the initial ground truth labels, or as a standalone module responsible for inference and spatially accurate map generation in informal settlements.

Class Module: Evaluator

The `Evaluator` class is designed to assess the performance of a segmentation model by generating predictions, overlaying them on images, and computing various metrics such as precision, recall, accuracy, dice coefficient, and Intersection over Union (IoU).

Configuration and Initialization

Input Arguments:

- `project_dir (str)`: Path to the project directory, which should contain models, images, and masks for evaluation.

- `config_name` (`str`, optional): The configuration file name. If missing, the constructor will look for a single file in the project directory.
- `generate_preds` (`bool`, optional): Flag indicating whether predictions should be generated during evaluation, `False` by default.
- `model_path` (`str`, optional): Custom path to the trained model file. If not provided, the model version specified in the configuration file is used, or a single directory will be looked for.

Configuration Settings:

The configuration file (`project_config.yaml`) must specify:

- `seed`: Seed for random number generation to ensure reproducibility.
- `model_version`: Identifier for the model version to be evaluated.

Directory Structure:

The project directory is expected to contain:

- `tiles/test/images/`: Directory with images for evaluation.
- `tiles/test/masks/`: Directory with ground truth masks corresponding to the test images.
- `models/`: Directory containing the trained model files.
- `eval/`: (optional) Directory where evaluation results, including overlays and metrics, will be saved.
- `shapefiles/` (optional): Directory for storing vectorized prediction outputs. Those will be generated if requested.
- `predictions/` (optional): Directory for storing raster prediction outputs. Those will be generated if requested.

Key Methods

- `overlay_shapefiles_on_images(n_images, show=False)`: Generates overlays of predicted shapefiles on corresponding images. This method can either display the images or save them to disk.
- `compute_metrics(map_gen, iou_threshold=0.5)`: Calculates evaluation metrics based on the comparison between predicted and ground truth data. It utilizes an instance of `MapGenerator` to convert raster masks to vector shapefiles for evaluation.
- `evaluate(n_images=10, iou_threshold=0.5)`: Orchestrates the evaluation process by optionally generating predictions, overlaying predictions on images, computing metrics, and saving the results.

Private Methods

- `calculate_building_iou(poly1, poly2)`: Computes the IoU between two polygon geometries. This function is used internally by `compute_metrics` to calculate building-level IoU values.

Usage Example

```
from segmentation.eval import Evaluator

project_dir = 'path/to/project/directory'
config_name = 'project_config.yaml'
generate_preds = True
```

```
evaluator = Evaluator(project_dir, config_name, generate_preds)
evaluator.evaluate(n_images=10, iou_threshold=0.3)
```

This command evaluates the segmentation model specified in the `project_config.yaml` file, generating predictions, overlaying the first 10 predicted shapefiles on their corresponding images, computing metrics, and saving the results.

Expected Outputs

- **Overlaid Images:** If `show` is `False`, overlaid images are saved in the `eval` directory with the naming convention `eval_pred_{image_file_name}`.
- **Metrics:** A CSV file named `{model_version}_metrics.csv` containing precision, recall, accuracy, dice coefficient, IoU, and building-level precision and recall at the specified IoU threshold. This file is saved in the `eval` directory.

BaseClass

The `BaseClass` serves as a shared abstract utility within the BEAM codebase, designed to streamline the management of directory structures and configurations used across the project's workflow. This class helps with the organization of data, models, and outputs by ensuring the necessary directories are prepared and accessible for various operations such as training, evaluation, and inference.

Initialization

`BaseClass` initializes with a project directory and lists of directories for reading and writing. It verifies the project directory exists and sets up the directory structure based on `read_dirs` and `write_dirs`. This includes creating new directories or clearing existing ones for overwriting.

Key Methods

- `load_config`: Loads a YAML configuration file, returning it as a dictionary. This method enables access to project settings and parameters.
- `load_dir_structure`: Prepares the project's directory structure based on `read_dirs` and `write_dirs`. It ensures required directories are present and sets class attributes for directory paths.
- `load_model_path`: Retrieves the path to a model file for either fine-tuning or evaluation. It checks for the existence of the model directory and ensures only one model file is present.
- `create_if_not_exists`: Ensures a directory exists by creating it if necessary. It also supports overwriting non-empty directories, useful for starting fresh.

These methods provide functionality for managing the project's directory and configuration needs, simplifying project setup and maintenance.

FUNCTIONAL COMPONENTS

Transform

This module provides functionality to split satellite imagery and corresponding mask or weight files into training and testing sets. It ensures that the dataset is divided based on a specified proportion, facilitating the model training and evaluation process by segregating data into distinct sets.

Key Functions

- `count_buildings(buildings, tile_geom)`:
 - **Purpose**: Counts the number of buildings within a given tile based on the intersection of building geometries and the tile's geometry.
 - **Parameters**:
 - `buildings` (`GeoDataFrame`): A dataset of building labels.
 - `tile_geom` (`Polygon`): The geometry of the tile.
 - **Returns**: The number of buildings within the specified tile (`int`).
- `calculate_average_confidence(buildings, tile_geom)`:
 - **Purpose**: Calculates the average confidence score for buildings within a given tile, aiding in assessing the reliability of the building labels.
 - **Parameters**:
 - `buildings` (`GeoDataFrame`): A dataset of building labels.
 - `tile_geom` (`Polygon`): The geometry of the tile.
 - **Returns**: The average confidence score for buildings within the tile (`float`).
- `gen_train_test(root_dir, test_size=0.2, seed=2022, distance_weighting=False)`:

- **Purpose**: Splits image and corresponding mask or weight files into training and testing sets and organizes them into appropriate directories.
- **Parameters**:
 - `root_dir` (`str` or `Path`): The directory containing all project tiles.
 - `test_size` (`float`, optional): The proportion of the dataset to include in the test split. Defaults to 0.2.
 - `seed` (`int`, optional): The random seed used for splitting the data. Defaults to 2022.
 - `distance_weighting` (`bool`, optional): Indicates whether to include distance weighting files in the split. Defaults to `False`.
- **Raises**:
 - `IOError`: If the images directory does not exist or a corresponding mask/weight file is missing.
- **Returns**: `None`. This function performs file operations and does not return any value.
- **Note**: This function expects mask and weight files to match the name of an image file.

Usage Example

```
from preprocess.transform import gen_train_test

# Define the root directory of your project

project_dir = "/path/to/your/project"

# Split the dataset into training and testing sets with a test size of 20%

gen_train_test(project_dir, test_size=0.2, seed=42,
distance_weighting=True)
```

This example demonstrates how to use the `gen_train_test` function to split the dataset into training and testing sets, including handling of distance weighting files if required.

Expected Outputs

- The `gen_train_test` function reorganizes the project directory by creating `test` and `train` subdirectories for images, masks, and optionally weights. It ensures that each set is representative of the overall dataset, facilitating effective model training and validation.

Sample

This module automates the process of identifying and preparing raster tiles from informal settlements for labeling or analysis purposes. It includes functionalities for filtering tiles based on their overlap with settlement areas, sampling a specified number of tiles and converting them to PNG format for LabelStudio or manual review.

Key Functions

- `tile_in_settlement(tile, settlements)`
 - **Purpose:** Determines whether a given raster tile overlaps with any polygons in a GeoDataFrame representing informal settlements.
 - **Parameters:**
 - `tile (DataArray)`: The raster tile to check.
 - `settlements (GeoDataFrame)`: A GeoDataFrame containing polygons of informal settlements.
 - **Returns:** `True` if the tile overlaps with any settlement polygons.
- `include_tile(tile_path, settlements)`
 - **Purpose:** Helper function to determine if a tile should be included in the sampling based on its overlap with settlement areas.
 - **Parameters:**
 - `tile_path (Path)`: Path to the raster tile.
 - `settlements (GeoDataFrame)`: GeoDataFrame of informal settlements.
 - **Returns:** The path to the tile if it overlaps with settlements, `None` otherwise.
- `sample_tiles(tile_directory, shp_dir, sample_size, seed_id=2022)`
 - **Purpose:** Samples a specified number of raster tiles from informal settlements for analysis or training.
 - **Parameters:**
 - `tile_directory (str or Path)`: Directory containing raster tiles.
 - `shp_dir (str or Path)`: Directory containing shapefiles of informal settlements.
 - `sample_size (int)`: Number of tiles to sample.
 - `seed_id (int, optional)`: Seed for random sampling. Defaults to 2022.
 - **Returns:** A list of paths to the sampled raster tiles.
- `create_sample_dir(image_tiles_dir, sampled_tile_paths)`
 - **Purpose:** Copies sampled tiles to a designated directory and converts them to PNG format.
 - **Parameters:**
 - `image_tiles_dir (str or Path)`: Directory containing the original image tiles.

- `sampled_tile_paths (list of Path)`: Paths to the image tiles that have been sampled.
 - **Returns:** `None`. Performs file operations to copy and convert tiles.
- `generate_label_json(label_file, tiff_file, output_file, tile_size=512) (For Future Development)`
 - **Purpose:** Intended to generate a JSON file containing label data in a format expected by LabelStudio for a given image tile.
 - **Parameters:**
 - `label_file (str or Path)`: Path to the vector data (shapefile) containing labels.
 - `tiff_file (str or Path)`: Path to the raster tile (TIFF).
 - `output_file (str or Path)`: Path where the output JSON will be saved.
 - `tile_size (int, optional)`: Size of the tile in pixels. Defaults to 512.
 - **Returns:** `None`.

Expected Outputs

- **Sampled Tiles Directory:** A new directory named `sample/images` containing the sampled raster tiles.
- **PNG Conversion Directory:** A new directory named `sample/png` containing the PNG conversions of the sampled tiles for easier visualization.

Usage Scenarios

- **Data Preparation for Machine Learning:** Selecting a representative subset of tiles from large datasets for training or testing machine learning models on informal settlements.
- **Visualization:** Converting geospatial raster data into PNG format for visualization, manual inspection, or annotation tasks.

Example Usage

```
from pathlib import Path

from preprocess.sample import sample_tiles, create_sample_dir

# Define directories

tile_directory = Path("/path/to/tile_directory")

shp_dir = Path("/path/to/shapefile_directory")
```



```
sample_size = 100

# Sample tiles from informal settlements

sampled_tile_paths = sample_tiles(tile_directory, shp_dir, sample_size)

# Create a sample directory and convert sampled tiles to PNG

create_sample_dir(tile_directory, sampled_tile_paths)
```

This module streamlines the process of preparing geospatial data for labeling and visualization, enhancing the efficiency of dataset creation and model training workflows by focusing on areas of interest within informal settlements.

Module: Losses

This module introduces custom loss functions designed for the image segmentation task, combining traditional loss functions with modifications to enhance model performance on specific challenges such as class imbalance and boundary precision.

Loss Functions

- **CombinedLoss**
 - **Description:** Combines Dice Loss and Focal Loss to leverage the advantages of both. While Dice Loss helps with class imbalance by focusing on the overlap between predicted and target masks, Focal Loss reduces the relative loss for well-classified pixels, directing focus towards hard-to-classify ones.
 - **Parameters:**
 - `axis` (int): The axis to compute the loss across.
 - `smooth` (float): Smoothing factor for Dice Loss to avoid division by zero.
 - `alpha` (float): Weighting factor to balance the two losses.
- **CrossCombinedLoss**
 - **Description:** Merges Cross Entropy Loss and Dice Loss. This combination benefits from the pixel-wise evaluation of Cross Entropy and the global evaluation of Dice Loss, making it effective for segmentation tasks with imbalanced classes.
 - **Parameters:**

- `pixel_weights` (Tensor, optional): Weights for each pixel in Cross Entropy Loss.
- `smooth` (float): Smoothing factor for Dice Loss.
- `alpha` (float): Weighting factor to balance the two losses.
- `axis` (int): The axis to compute the loss across.
- **WeightedCrossCombinedLoss**
 - **Description:** Enhance Cross-entropy Loss by enabling the incorporation distance weights for each sample, combined with Dice Loss. This approach is useful for emphasizing the importance of certain regions within an image, such as with distance weighting.
 - **Parameters:**
 - `smooth` (float): Smoothing factor for Dice Loss.
 - `alpha` (float): Weighting factor to balance the two losses.
 - `axis` (int): The axis to compute the loss across.
- **DualFocalLoss**
 - **Description:** Implements the loss proposed in [this paper](#), focusing on addressing the issue of class imbalance by applying a dual approach to Focal Loss, which considers both foreground and background classes.
 - **Parameters:**
 - `ignore_lb` (int): Label to ignore in the loss computation.
 - `eps` (float): Epsilon value to avoid logarithm of zero.
 - `reduction` (str): Specifies the reduction to apply to the output: `'mean'`, `'sum'`, or `'none'`.

Helpers

The Helpers component provides a suite of utility functions designed to manage recurring operations within the BEAM Model Training pipeline, including for instance reproducibility, timestamping, coordinate transformation, image processing, and file management.

Key functions

- `seed(seed_value=0)`: Initializes the random number generators with a specified seed value to ensure reproducible results. The `seed_value` argument sets the seed for Python's `random` module, NumPy, and PyTorch.
- `timestamp()`: Generates a timestamp string in "YYYYMMDD-HHMM" format, adjusted to the CET timezone. Used for creating unique identifiers based on the current time.

- `crs_to_pixel_coords(x, y, transform)`: Converts geographic coordinates (x, y) in a Coordinate Reference System (CRS) to pixel coordinates within an image, using the provided `transform` matrix (a `rasterio.Affine` object).
 - `get_rgb_channels(input_data)`: Extracts or constructs RGB channels from the provided `input_data`, which can be a path to a TIFF file (str or `pathlib.Path`) or an `xarray.DataArray`. It supports RGBA images and multispectral satellite images by selecting or combining bands to form an RGB image.
 - `multiband_to_png(file_path, output_dir)`: Converts a multiband TIFF file specified by `file_path` to a PNG file and saves it to the `output_dir`. This function handles different band configurations to ensure the output is suitable for visualization and export.
 - `get_tile_size(image_path)`: Determines the size of a square tile from an image file specified by `image_path`.
 - `copy_leaf_files(src_dir, dest_dir)`: Copies all leaf files from the source directory (`src_dir`) to the destination directory (`dest_dir`) without overwriting existing files, preserving directory structure.
- These utility functions automate common tasks and ensuring consistency and reproducibility throughout the workflow.

FINAL NOTE

This document is intended to help with the transition and handover of the codebase to future users, developers, analysts relying on this infrastructure. By nature, this document will grow stale as new features and improvements are being added to the codebase. It is recommended to keep this mind when reading, and to update, when appropriate, any discrepancies with the code base at time of reading.



ONU-HABITAT

PROGRAMA DE LAS NACIONES
UNIDAS PARA LOS ASENTAMIENTOS
HUMANOS (ONU-HABITAT)

Contacto



onu-habitat.org

