



UNIVERSIDAD DE LAS
FUERZAS ARMADAS "ESPE"



DEPARTAMENTO DE CIENCIAS DE
LA TIERRA Y DE LA
CONSTRUCCIÓN



INGENIERÍA
GEOGRÁFICA Y DEL
MEDIO AMBIENTE

DEPARTAMENTO DE CIENCIAS DE LA TIERRA Y DE LA CONSTRUCCIÓN

INGENIERÍA GEOGRÁFICA Y DEL MEDIO AMBIENTE

“Generación de ortoimágenes de diferente nadir con pares estereoscópicos satelitales Worldview, y cartografía con Deep Learning a escala 1:5000 en el norte del DMQ”

Autores

Carrasco Puga, Glenda Gisela
Moreno Carrillo, Daniela Alejandra

Director del proyecto

Ing. Kirby Powney, Eduardo

Docente evaluador

Ing. Padilla Almeida, Oswaldo PhD

Director del carrera

Ing. Robayo Nieto, Alexander Msc.

Secretaria académica

Ab. Benavides Guzmán, Michelle

AGOSTO 2022

TABLA DE CONTENIDOS

PLANTEAMIENTO
DEL PROBLEMA

01



05

CONCEPTOS Y
GENERALIDADES

JUSTIFICACIÓN E
IMPORTANCIA

02



06

METODOLOGÍA

OBJETIVOS

03



07

RESULTADOS

ÁREA DE ESTUDIO

04




08

CONCLUSIONES Y
RECOMENDACIONES


01 PLANTEAMIENTO DEL PROBLEMA

La expansión de las ciudades y el cambio en la cobertura de la tierra son algunas de las principales razones por las cuales la documentación de la realidad urbana necesita ser actualizada de manera constante.



La ventaja de elaborar cartografía a partir de imágenes satelitales es que permite obtener información de manera sistemática y eficaz debido a la alta resolución de los satélites.

- La tecnología NTRIP permite realizar correcciones de GPS en tiempo real a través de internet.



- El Deep Learning ha permitido optimizar el tiempo de extracción de cartografía, reducir los costos y el personal de trabajo.



02 JUSTIFICACIÓN E IMPORTANCIA



En la actualidad se desea obtener información de la superficie de la Tierra de manera rápida y con bajos costos de adquisición.



Obtener esta información de un sitio web permite dar a las imágenes satelitales una ventaja sobre los levantamientos topográficos o fotografías aéreas de drones.



Se propondrá una alternativa para generar cartografía que pueda ser de utilidad para la planificación del país.




Evaluar la precisión horizontal en ortoimágenes obtenidas a partir de imágenes satelitales WorldView que poseen diferente nadir, mediante la aplicación de NTRIP.

03 OBJETIVOS

OBJETIVO GENERAL

Generar ortoimágenes de diferente nadir con pares estereoscópicos satelitales WorldView por correlación, y cartografía con Deep Learning a escala 1:5000 en el norte del DMQ que servirán como una técnica alternativa para la obtención de insumos geospaciales.

OBJETIVOS ESPECÍFICOS



Recopilar y estandarizar la información secundaria en base al área de intervención y sistema de referencia para la generación del proyecto.



Tomar puntos de control GNSS a partir de la aplicación de diferentes métodos de posicionamiento que servirán como insumos para la ortorrectificación de las imágenes y evaluar la exactitud posicional de las ortoimágenes y cartografía.

03 OBJETIVOS

OBJETIVOS ESPECÍFICOS



Ortorrectificar las imágenes satelitales de pares estereoscópicos con diferente nadir a partir de LPS Core (ERDAS Imagine) utilizando aerotriangulación directa o aerotriangulación combinada con los Coeficientes Polinomiales Racionales (RPC) con la finalidad de obtener las ortoimágenes y los Modelos Digitales de Superficie por correlación para escala 1:5000 considerando las áreas de intervención.



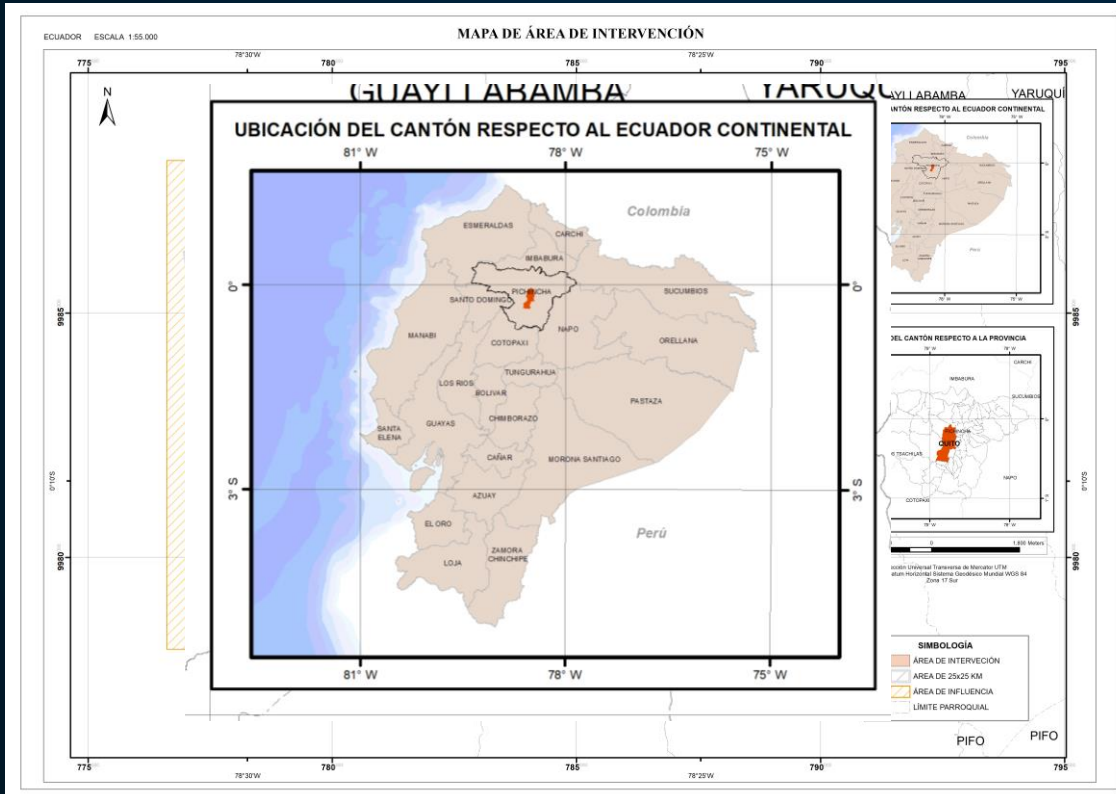
Generar cartografía aplicando las técnicas de interpretación – digitalización y Deep Learning en objetos puntuales, lineales y superficiales para un área de aproximadamente 200 Ha dentro de la extensión de las ortoimágenes.



Evaluar la calidad y exactitud posicional de los productos obtenidos a través de la aplicación de las normativas ISO 19157 y NSSDA, con el objeto de verificar si estos productos servirían como una técnica alternativa para la generación de insumos geospaciales 1:5000.

04 ÁREA DE ESTUDIO

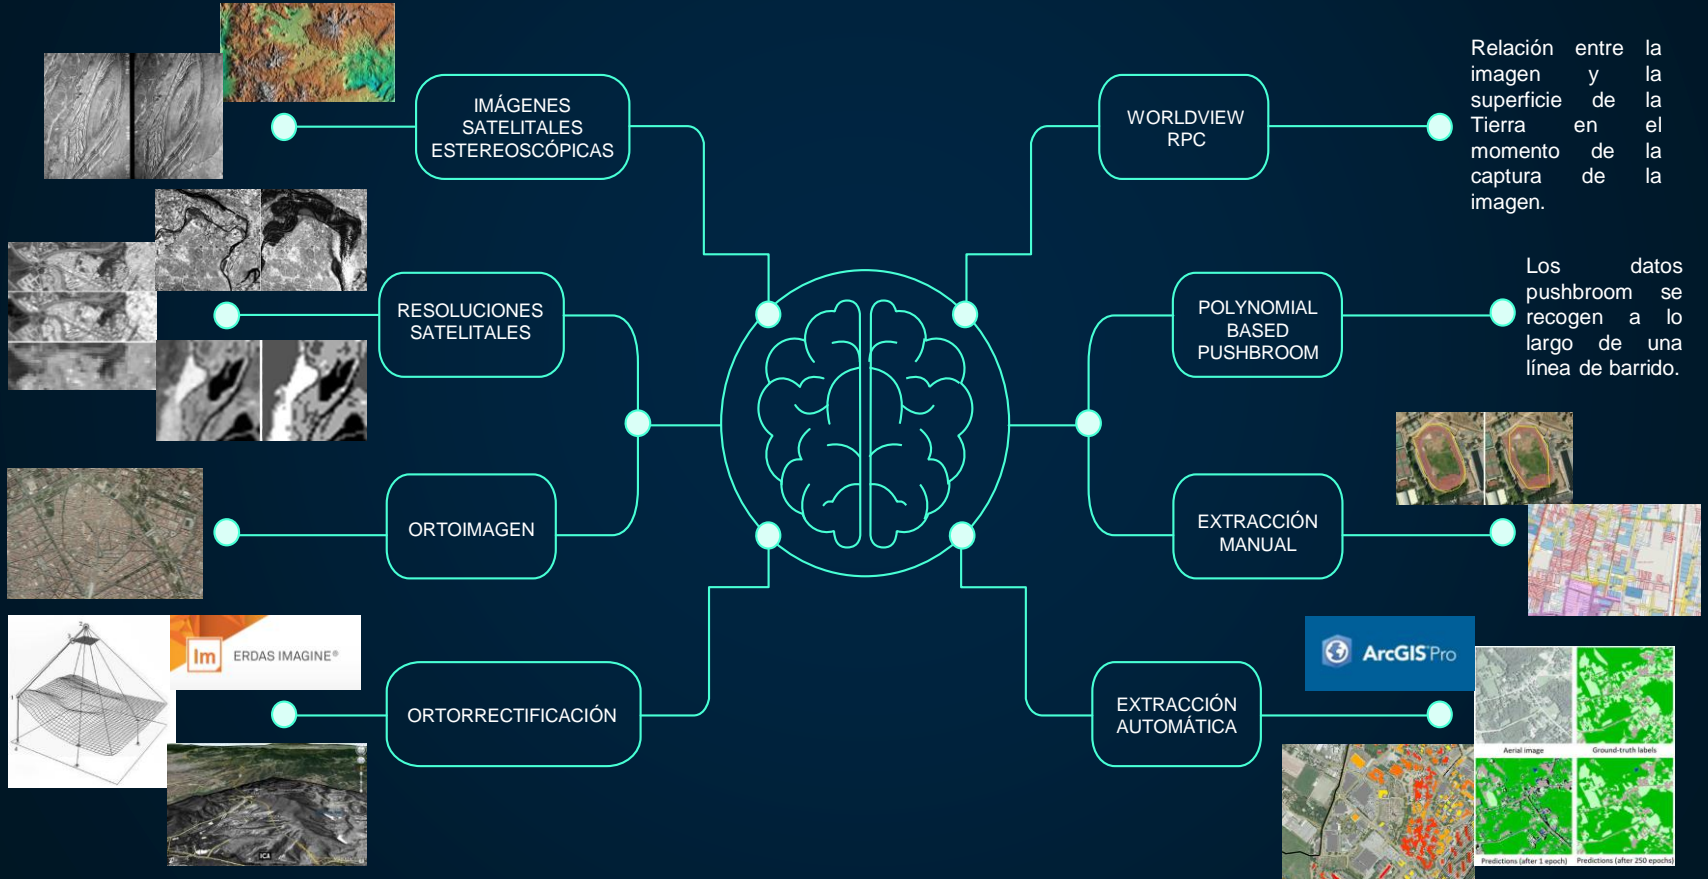
DISTRITO METROPOLITANO DE QUITO



Escenas de 10 x 10 km y de 5 x 5 km (100 km² y 25 km²), respectivamente; mientras que el área para generar cartografía es de aproximadamente 200 hectáreas dentro de las escenas mencionadas



05 CONCEPTOS Y GENERALIDADES




Relación entre la imagen y la superficie de la Tierra en el momento de la captura de la imagen.


Los datos pushbroom se recogen a lo largo de una línea de barrido.

05 CONCEPTOS Y GENERALIDADES

SEGMENTACIÓN




- * MODELO UNET
- * MODELO BDCN



- Clasificación de píxeles a partir de la segmentación de una imagen.
- Se basará en contrastes, colores, entre otros.

GENERALIZACIÓN



CARTOGRAFÍA PLANIMÉTRICA

Catálogo de Objetos del IGM

PROTOCOLO NTRIP

Posicionamiento en tiempo real.

- Ubicación conocida.
- Trabajo de campo.

PUNTOS DE CONTROL

CONTROL DE CALIDAD

- Norma ISO 19157:2013.
- Norma NSSDA.

- Tamaño de muestra.
- IGM.

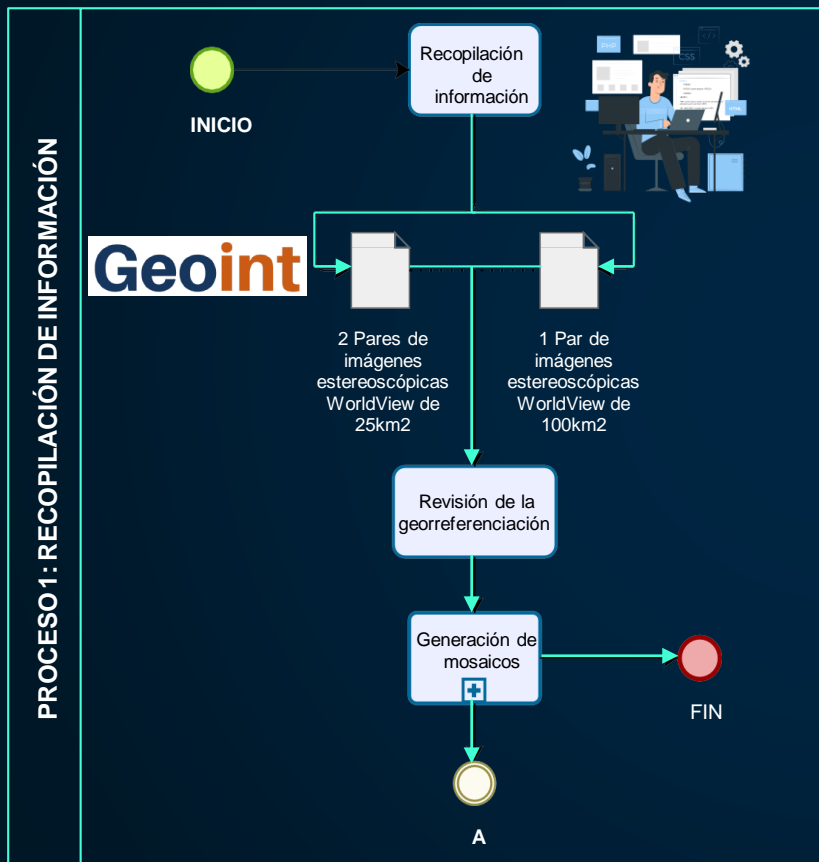
EXACTITUD POSICIONAL

ESTADÍSTICOS



06 METODOLOGÍA

Imágenes satelitales estereoscópicas de los sensores WorldView-2 y WorldView-3 de los años 2014, 2016 y 2018




Características	Años		
	2014	2016	2018
Tipo de sensor	WorldView-3	WorldView-2	WorldView-3
Cobertura	100 km ²	25 km ²	25 km ²
Nadir	13.1°	26.0°	27.7°
Porcentaje de nubes	1.0%	2.8%	5.7%
Número de Bandas	4	4	4
Resolución Espacial	0.40 m	0.50 m	0.40 m
Resolución Radiométrica	8 bits	8 bits	8 bits
Traslapo	99.8%	96.6%	99.18%
Sistema de Referencia	WGS84		
Proyección	UTM, 17S		

06 METODOLOGÍA

REVISIÓN DE GEORREFERENCIACIÓN

CONTROL TERRESTRE

2014



2018



2016



Imágenes Satelitales Año	Área Km ²	Distancias (m)
2014	100 km ²	37.836
		29.637
		24.287
2016	25 km ²	23.063
		22.947
		48.247
2018	25 km ²	38.261
		23.498
		36.161

06 METODOLOGÍA



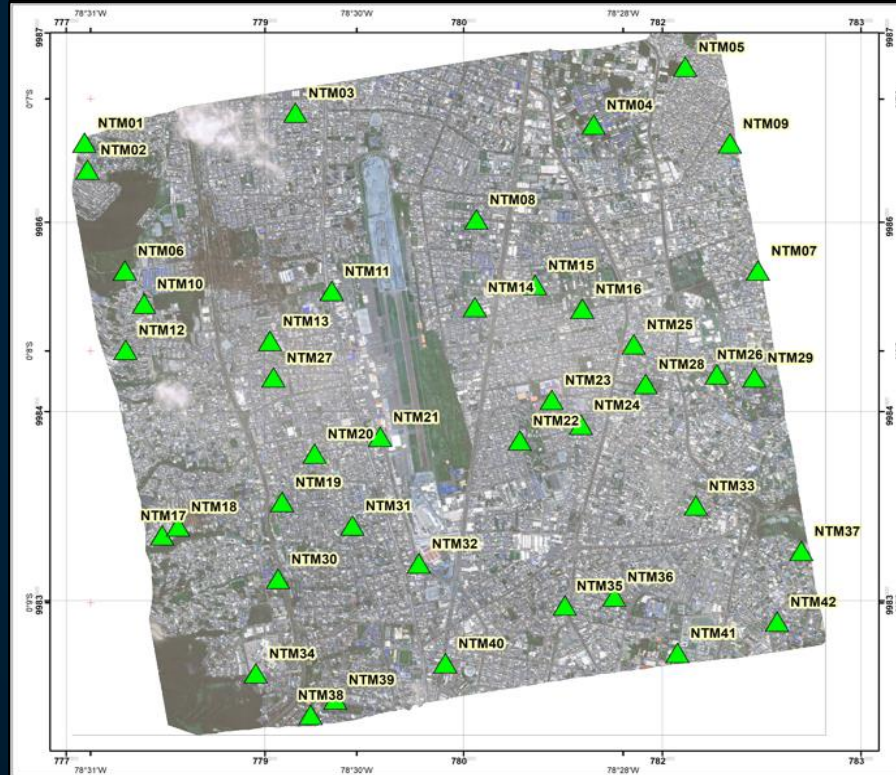
Planificación de la ubicación de los GCP

Cálculo del número de puntos GPS para la corrección geométrica y generación de una ortoimagen de alta resolución en áreas de baja y mediana pendiente; Kirby, E, 2012.

42GCP - 2014

42GCP - 2016

42GCP - 2018



06 METODOLOGÍA



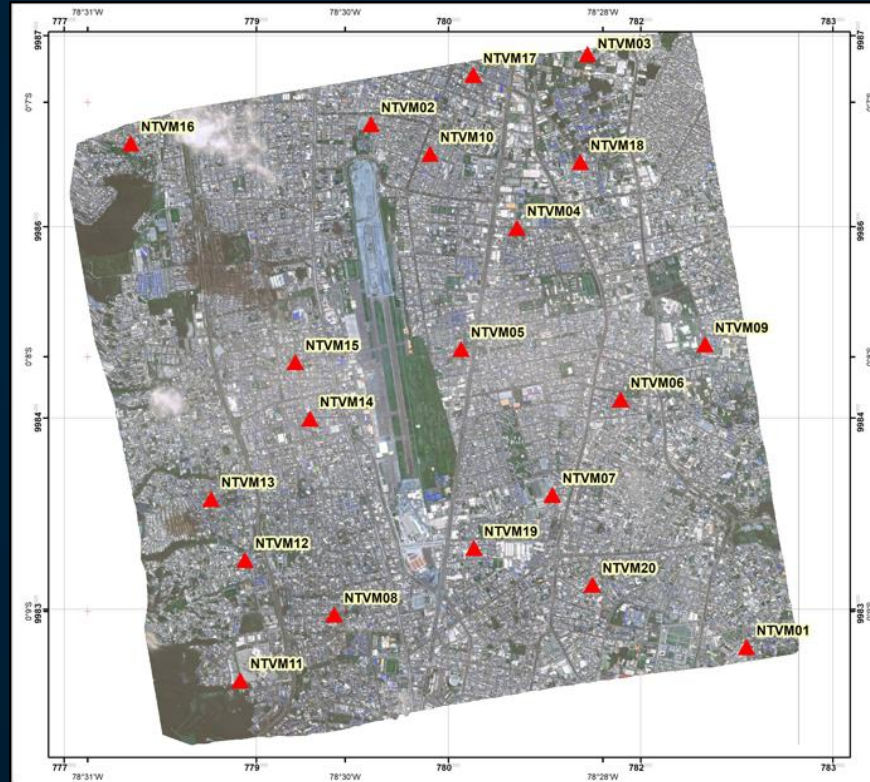
Planificación de la ubicación de puntos de exactitud posicional

CONTROL TERRESTRE

20 Puntos - 2014


20 Puntos - 2016

20 Puntos - 2018



AGOSTO 2022

06 METODOLOGÍA



Planificación de la ubicación de puntos de validación para cartografía

Reconocimiento de campo

- Logística
- Distancia
- Optimización de recursos

Toma de puntos de apoyo

- Sin materialización
- Receptor GNSS doble frecuencia TRIMBLE R8
- NTRIP

Toma de puntos de validación

- ASPRS: 20 puntos de validación

Evaluación de precisión de GCP y puntos de validación

$$PH_{GCP} = 0.01 \text{ cm} * 5000$$

$$PH_{GCP} = 50 \text{ cm}$$

$$P_{GCP} = \frac{1.5}{4}$$

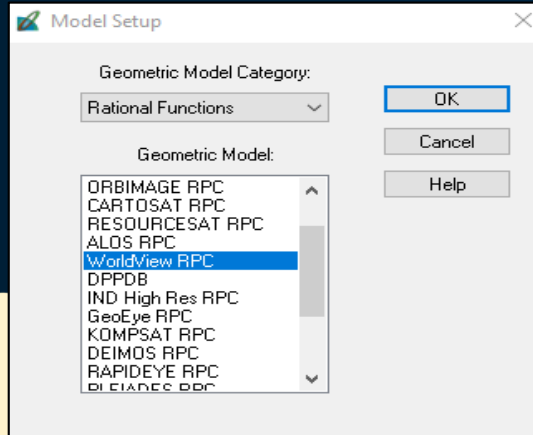
$$P_{GCP} = 37.5 \text{ cm}$$

(IGM, 2006)

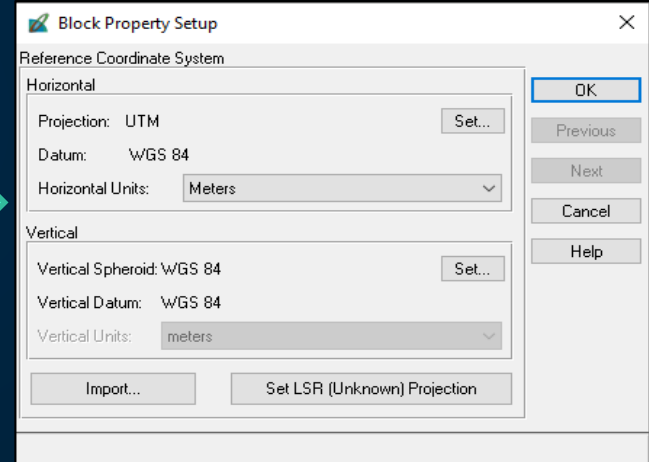
06 METODOLOGÍA

Generación de ortoimágenes por aerotriangulación combinada con los Coeficientes Polinomiales Racionales (RPC)

GENERACIÓN DE ORTOIMÁGENES



CONFIGURACIÓN DEL MODELO DEL SENSOR



CONFIGURACIÓN DEL SISTEMA DE REFERENCIA



AGOSTO 2022



06 METODOLOGÍA

Orientación interior RPC




FORMATO .TIL



FORMATO .RPB



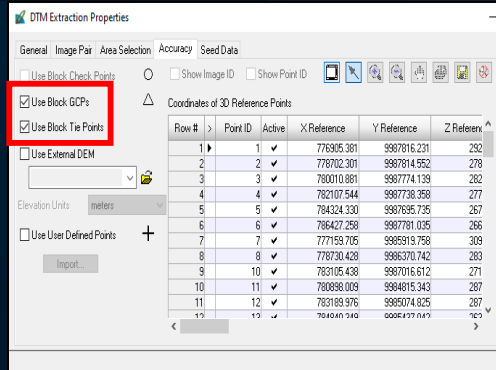
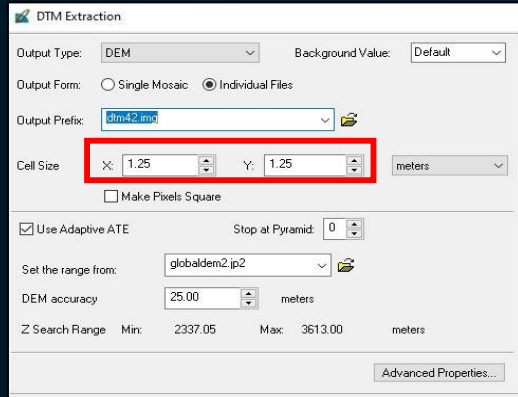
Orientación exterior RPC




Compute image coordinates from the ground points

06 METODOLOGÍA

Generación de MDS por correlación con RPC



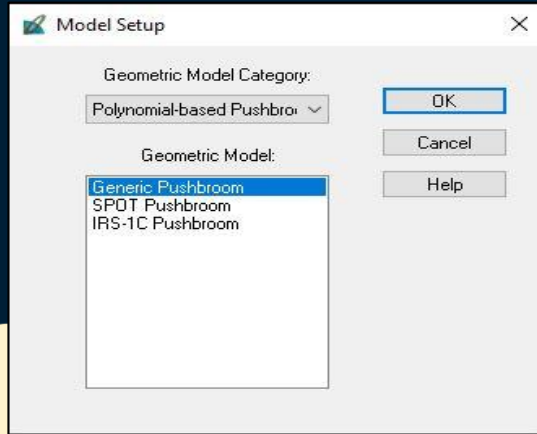
Generación de ortomagen por correlación con RPC



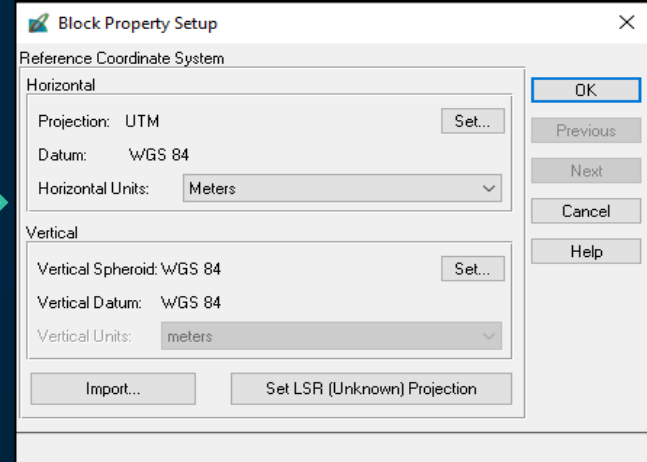

06 METODOLOGÍA

Generación de ortoimágenes por aerotriangulación directa

GENERACIÓN DE ORTOIMÁGENES



CONFIGURACIÓN DEL
MODELO DEL SENSOR



CONFIGURACIÓN DEL
SISTEMA DE REFERENCIA



AGOSTO 2022

06 METODOLOGÍA

Orientación interior

Sensor Information

General | Model Parameters

Sensor Name:

Description:

Focal Length (mm):


Principal Point x0 (mm):

Principal Point y0 (mm):

Pixel Size (mm):

Sensor Columns:

Orientación exterior



CONTINUA

06 METODOLOGÍA

Orientación exterior

IMPORTACIÓN DE COORDENADAS DE REFERENCIA

Point #	Point ID	Description	Type	Usage	Active	X Reference	Y Reference	Z Reference
1	1	NTE01	Full	Control	✓	777139.284	9986131.847	3069.154
2	2	NTE02	Full	Control	✓	778043.847	9986139.861	2886.956
3	3	NTE03	Full	Control	✓	778730.411	9986370.754	2832.280
4	4	NTE04	Full	Control	✓	781084.983	9986855.270	2983.391
5	5	NTE05	Full	Control	✓	777442.059	9985118.785	2955.577
6	6	NTE06	Full	Control	✓	778622.287	9985489.245	2849.189
7	7	NTE07	Full	Control	✓	779090.825	9986063.677	2865.244
8	8	NTE08	Full	Control	✓	780983.066	9986275.753	2946.330

MODIFICACIÓN DE LOS PESOS DE CADA PUNTO

Triangulation

General Point Advanced Options

Ground Point Type and Standard Deviations (X,Y: meters, Z: meters)

Type: Different weighted values

X: 1.000000

Y: 1.000000

Z: 1.000000

CONVERGENCIA SUPERADA

Triangulation Summary

Triangulation Iteration Convergence: Yes

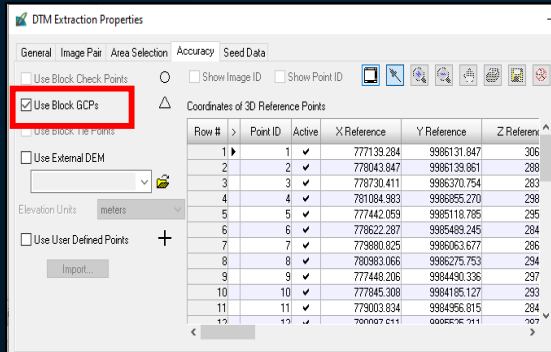
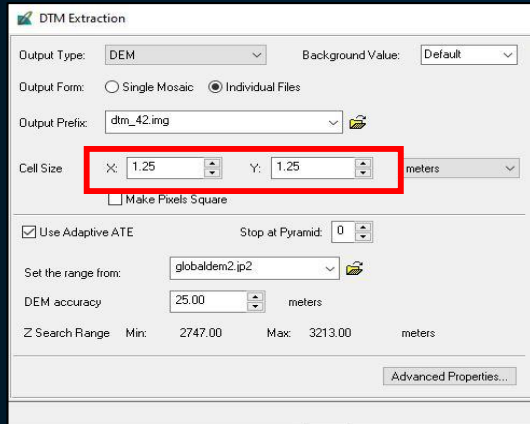
Total Image Unit-Weight RMSE: 0.7747512

Control Point RMSE: Check Point RMSE:

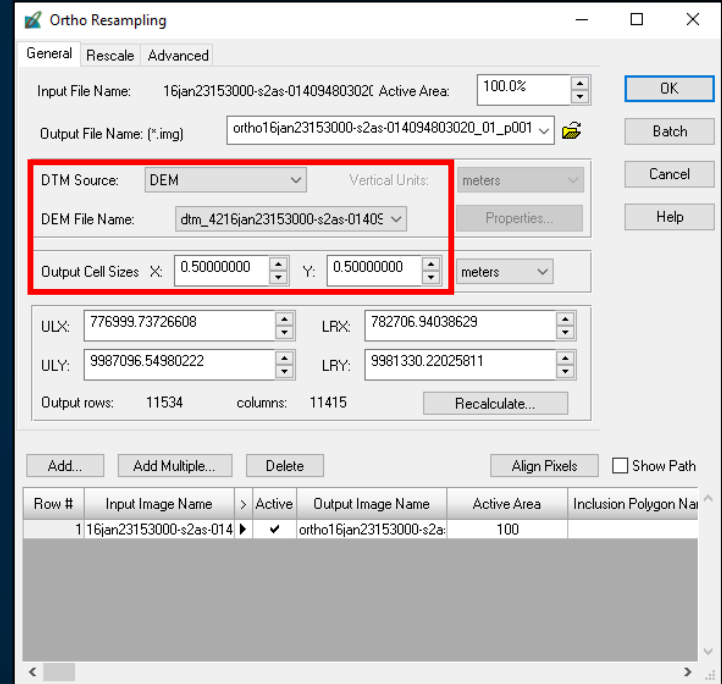
Ground X: 24.9911575 (42)	Ground X: 0.0000000 (0)
Ground Y: 15.0930157 (42)	Ground Y: 0.0000000 (0)
Ground Z: 28.9247570 (42)	Ground Z: 0.0000000 (0)
Image X: 2.9156120 (84)	Image X: 0.0000000 (0)
Image Y: 1.7271422 (84)	Image Y: 0.0000000 (0)

06 METODOLOGÍA

Generación de MDS por correlación con modelo Polynomial Based in Pushbroom



Generación de ortoimagen con modelo Polynomial Based in Pushbroom



06 METODOLOGÍA


Evaluación exactitud posicional planimétrica normas NSSDA e IGM de las ortoimágenes

Crear un shapefile que conste de 20 puntos de validación tomados en campo

Con respecto a la exactitud planimétrica, se debe tener en cuenta la tolerancia presentada en la norma IGM.



Distancia entre el punto de referencia y su homólogo en la ortoimagen



Aplicar la norma NSSDA con nivel de confianza al 95% y la norma IGM al 90%.



06 METODOLOGÍA

Evaluación exactitud posicional altimétrica de los MDS.

Calcular el valor de altitud del ráster (MDS) generado en la obtención de ortomágenes

Calcular la diferencia entre la altura elipsoidal del punto tomado en campo con respecto al extraído del MDS generado



Aplicar la norma NSSDA con nivel de confianza al 95%

FID	Shape *	Id	NORTE	ESTE	NEAR_FID	NEAR_DIST	RASTERVALU
0	Point	0	9987620.29644	777478.282202	0	0.277068	2881.224609
1	Point	0	9986169.85403	777526.261923	1	0.226325	2981.095459
2	Point	0	9986958.89507	779199.904008	2	0.608353	2809.595127
3	Point	0	9986847.08087	781083.862836	3	0.273536	2984.144531
4	Point	0	9987176.88569	784837.867286	4	0.476932	2661.534424
5	Point	0	9985502.88951	778662.700018	5	0.229794	2847.415283
6	Point	0	9984534.68818	780997.445952	6	0.462724	2839.434457
7	Point	0	9985445.50259	784607.842405	7	0.202979	2638.262995
8	Point	0	9984732.3192	784869.102485	8	0.76964	2641.395508
9	Point	0	9983542.67363	784952.689436	9	0.222478	2633.369629
10	Point	0	9982712.3107	785554.689682	10	0.283286	2596.466553
11	Point	0	9981939.69796	778373.080284	11	0.833897	2932.281006
12	Point	0	9978905.94171	778816.681104	12	1.9202	2994.140381
13	Point	0	9978283.49137	777903.062957	13	0.96851	2864.421631
14	Point	0	9979216.70722	779053.079213	14	0.296604	2633.036965
15	Point	0	9980115.51101	779919.486874	15	0.254809	2608.033008
16	Point	0	9980107.89826	781805.51125	16	0.271687	2945.802246
17	Point	0	9980569.49886	784238.706414	17	0.173342	2612.588623
18	Point	0	9978180.72015	783865.083479	18	0.274418	2502.84375
19	Point	0	9978338.6988	785545.567177	19	0.68821	2422.894287



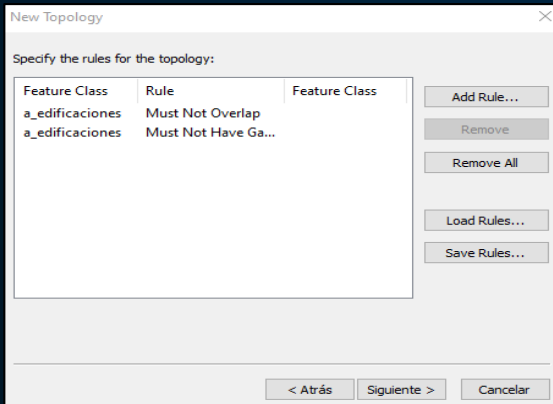
06 METODOLOGÍA

Generación de cartografía por digitalización

Área de 200 ha aproximadamente para realizar este proceso, adicional se generará una GDB



Se aplicará topología





N°	Feature Class	Categorías	Subcategorías	Descripción
1	cancha_a	Geografía Socioeconómica	Recreación	Lugar al aire libre destinado a eventos deportivos, pueden estar hechas de tierra, césped o cemento,
2	edificio_a	Geografía Socioeconómica	Construcciones	Casas y edificios, estructura techada relativamente permanente, diseñada para uso particular.
3	manzana_a	Demarcación	Linderos de propiedad	Espacio delimitado por vías o accidentes, superficie de terreno o agrupación de lotes
4	tierra_sin_vegetacion_a	Cobertura de la Tierra	Zona sin información	Terrenos baldíos, carece de fuentes de cobertura adecuadas.
5	parterre_a	Infraestructura de transporte	Asociado a Transportación	Espacio vial entre dos rutas de transporte para separar el flujo de tráfico o separar el sentido del mismo.
6	via_ruta_a	Infraestructura de transporte	Transporte terrestre	Espacio destinado al tránsito de vehiculos terrestres.
7	via_ruta_l	Infraestructura de transporte	Transporte Terrestre	Espacio destinado al tránsito de vehiculos terrestres.
8	arbol_p	Cobertura de la Tierra	Tierras forestales	Plantas perennes, de tronco leñoso, posee una altura considerable.

06 METODOLOGÍA

Generación de cartografía por deep learning

N	Elemento	Mínimo	Recomendación	Óptimo
1	CPU	2 núcleos, una CPU tendrá 4 subprocesos	4 núcleos	10 núcleos
2	Plataforma	64 bits	64 bits	64 bits
3	Almacenamiento	32 GB de espacio libre	32 GB o más de espacio libre en la SSD	
4	Memoria RAM	8 GB	32 GB	64 GB o más
5	Tarjeta Gráfica NVIDIA	CUDA 3.7	CUDA 6.1 o más	
6	Memoria Gráfica	6 GB	16 GB o más	
7	Caché de visualización	32 GB	32 GB o más	
8	Resolución de la pantalla	1024x768	1080px o superior	

Definición de clases

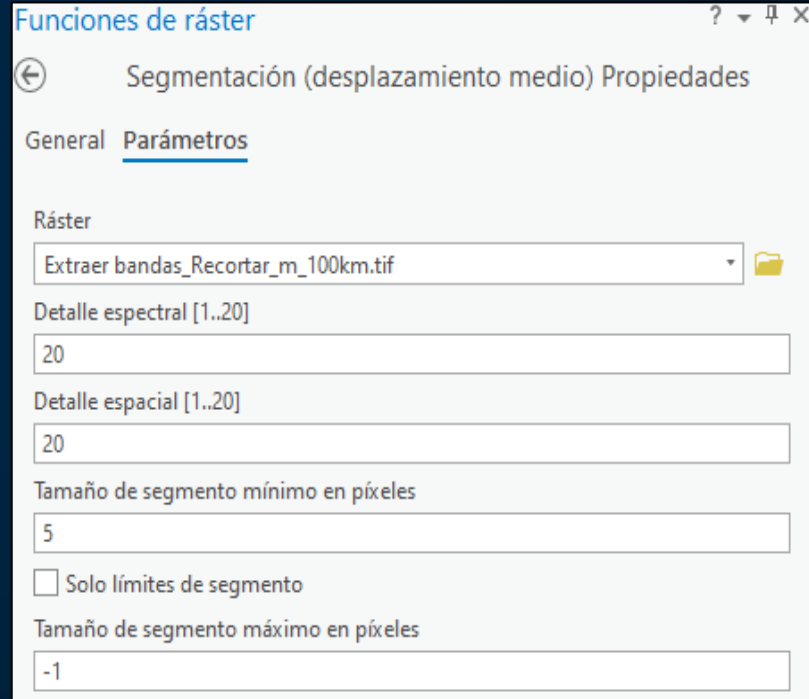



06 METODOLOGÍA

Generación de cartografía por deep learning

Segmentación:

- Colocar como ráster de entrada aquella imagen en la que deseamos extraer cartografía.
- Los valores de Detalle espectral, Detalle espacial y Tamaño de mínimo y máximo en píxeles, dependerá del tipo de estudio.
- Para realizar este proceso es necesario contar con una imagen de máximo 3 bandas



06 METODOLOGÍA

Generación de cartografía por deep learning

Extracción de datos de entrenamiento

Geoprociamiento

De polígono a ráster

Parámetros Entornos

Entidades de entrada
a_edificaciones_deep

Campo de valor
OBJECTID

Dataset ráster de salida
a_edificaciones_deep_PolygonToRaster1

Tipo de asignación de celdas
Centro de la celda

Prioridad del campo
NONE

Tamaño de celda
0.4

Construir tabla de atributos ráster

Reclasificación de datos de entrenamiento

Geoprociamiento

Reclasificar

Parámetros Entornos

Ráster de entrada
a_edificaciones_deep_PolygonToRaster

Campo Reclass
Value

Reclasificación

Invertir valores nuevos

Iniciar	Fin	Nuevo
0	1484	1
NODATA	NODATA	0

Clasificar Único

Ráster de salida
Reclass_a_ed2

Cambiar los valores ausentes por NoData

Verificar que este sea de tipo *Temático*

06 METODOLOGÍA

Generación de cartografía por deep learning

Exportar de datos de entrenamiento

Geoprosesamiento

Export Training Data For Deep Learning

Parámetros Entornos

Input Raster
SEGMENTACION.tif

Additional Input Raster

Output Folder
D:\ESPE\TESIS\RESULTADOS\DEEPLARNING\CHIPSDEEP

Input Feature Class Or Classified Raster Or Table
R_RECLASS.tif

Buffer Radius
0

Input Mask Polygons
AOI_TESIS

Image Format
TIFF format

Tile Size X
256

Tile Size Y
256

Stride X
128

Stride Y
128

Rotation Angle
0

Reference System
Map space

Output No Feature Tiles

Metadata Format
Classified Tiles

Entrenamiento del modelo

Geoprosesamiento

Train Deep Learning Model

Parámetros Entornos

Input Training Data
CHIPS1

Output Model
MODELO

Max Epochs
200

Model Parameters

Model Type
U-Net (Pixel classification)

Advanced

Learning Rate

Backbone Model
ResNet-152

Pre-trained Model

Validation %
10

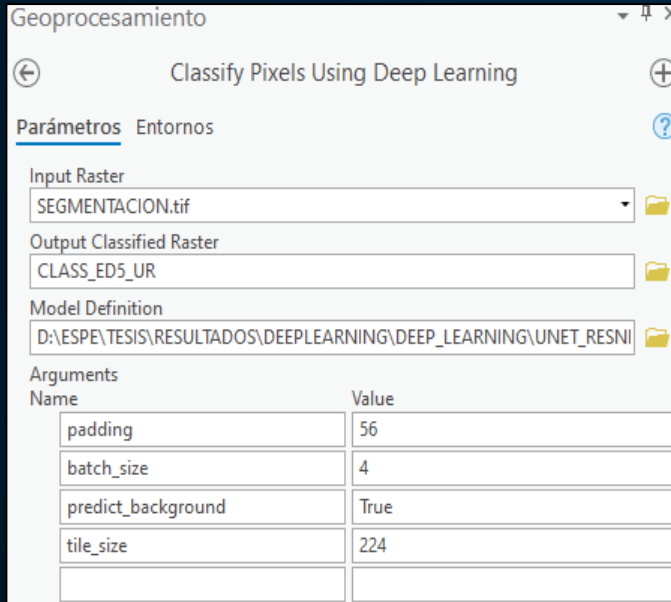
Stop when model stops improving

Freeze Model

06 METODOLOGÍA

Generación de cartografía por deep learning

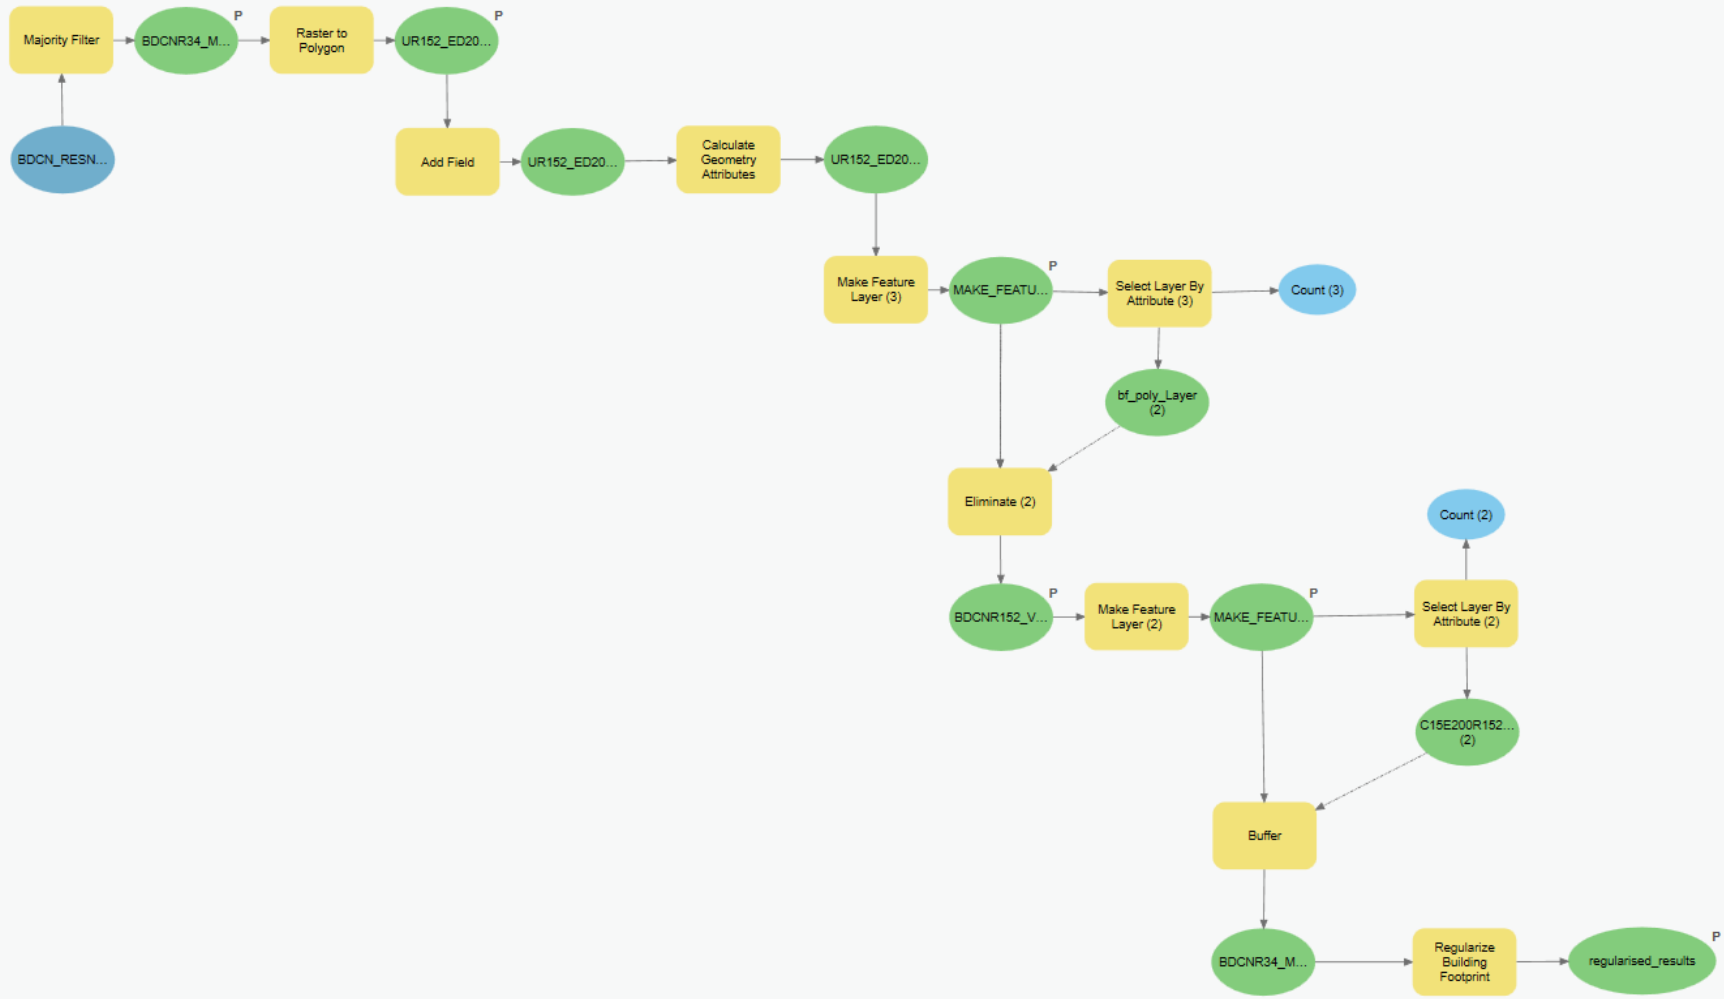
Extracción de clasificación del ráster



Generalización de datos de clasificación

- Majority Filter
- Raster to Polygon
- Add Field
- Calculate Geometry Attributes
- Make Feature Layer
- Select Layer by Attribute
- Eliminate
- Buffer
- Regularize Building Footprint

GENERACIÓN DE CARTOGRAFÍA

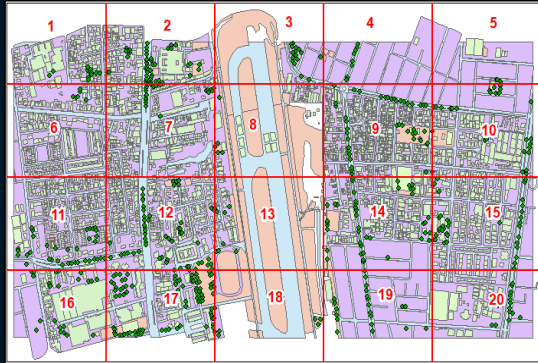


06 METODOLOGÍA

Exactitud espacial de productos cartográficos

Control de calidad de datos en base a la Norma ISO 19157

CONTROL DE COMPLECIÓN



CONSISTENCIA LÓGICA

Table

edificio_a	nam	acc	afc	cef
<Null>	<Null>	<Null>	<Null>	<Null>
<Null>	<Null>	<Null>	<Null>	<Null>
<Null>	-1.- Información	<Null>	<Null>	<Null>
<Null>	1.- Exacta	<Null>	<Null>	<Null>
<Null>	2.- Aproximada	<Null>	<Null>	<Null>
<Null>	3.- Dudosa	<Null>	<Null>	<Null>
<Null>	7.- Precisa	<Null>	<Null>	<Null>
<Null>	998.- No aplica	<Null>	<Null>	<Null>

Edificio	nam	Nombre
acc		Código de Categoría de Precisión Horizontal
afc		Código del Tipo de Instalación Agrícola
cef		Código del Tipo de Instalación Cultural
efe		Código del Tipo de Instalación Correos
cit		Código del Tipo de Instalación Comercial
ese		Código del Tipo de Instalaciones de Comunicaciones

acc	Código de Categoría de Precisión	
-1	-1.- Información no disponible	Cuando no se dispone o no se tiene certeza de los datos.
1	1.- Exacta	Cumple con los requisitos de precisión.
2	2.- Aproximada	No cumple con los requisitos exactos de precisión, sin embargo se considera suficiente.
3	3.- Dudosa	No se cumplen los requisitos de precisión y probablemente tampoco los datos son suficientemente precisos para la mayoría de usos.
7	7.- Precisa	Supera los requisitos de precisión especificados.
998	998.- No aplica	Cuando el atributo no se relaciona con el objeto.

CONSISTENCIA DE EXACTITUD POSICIONAL

Norma IGM

RMSE

Exactitud R

Si $RMSE_x = RMSE_y \rightarrow$
 Exactitud $r = 1.5175(RMSE_r)$

Si $RMSE_x \neq RMSE_y \rightarrow$
 Exactitud $r = 2.1460 \times 0.5 \times (RMSE_x + RMSE_y)$

(FGDC, 1998), (IGM, 2018)

07 RESULTADOS

Resultados de las precisiones de puntos de apoyo de los años 2014, 2016 y 2018


Año	Media (m)	Desv. Est (m)	Dist. Max (m)	Dist. Min (m)
2014	0.019	0.007	0.040	0.008
2016	0.023	0.009	0.042	0.009
2018	0.023	0.009	0.044	0.010

Resultados de las precisiones de puntos de verificación de los años 2014, 2016 y 2018

Año	Media (m)	Desv. Est (m)	Dist. Max (m)	Dist. Min (m)
2014	0.020	0.009	0.042	0.008
2016	0.021	0.009	0.042	0.009
2018	0.020	0.008	0.038	0.009

07 RESULTADOS

Generación de MDS para cada modelo




Buena correlación



Correlación justa



Excelente correlación




07 RESULTADOS

Resultados de la generación de ortoimágenes

AEROTRIANGULACIÓN RPC



AEROTRIANGULACIÓN DIRECTA



AGOSTO 2022

07 RESULTADOS

Resultados de media, desviación estándar, máximo y mínimo de las ortoimágenes año 2016

Año	Área Km ²	# Puntos	Media (m)	Desv. Est (m)	Dist. Máx (m)	Dist. Min (m)
Ortoimágenes 2016	25 km ²	42	31.00	15.23	68.51	13.36
		30	30.95	15.20	68.47	13.65
		21	31.07	15.22	68.43	13.66
		9	31.03	15.24	68.46	13.62
		7	31.00	15.16	68.45	13.67


07 RESULTADOS

Cartografía digitalizada

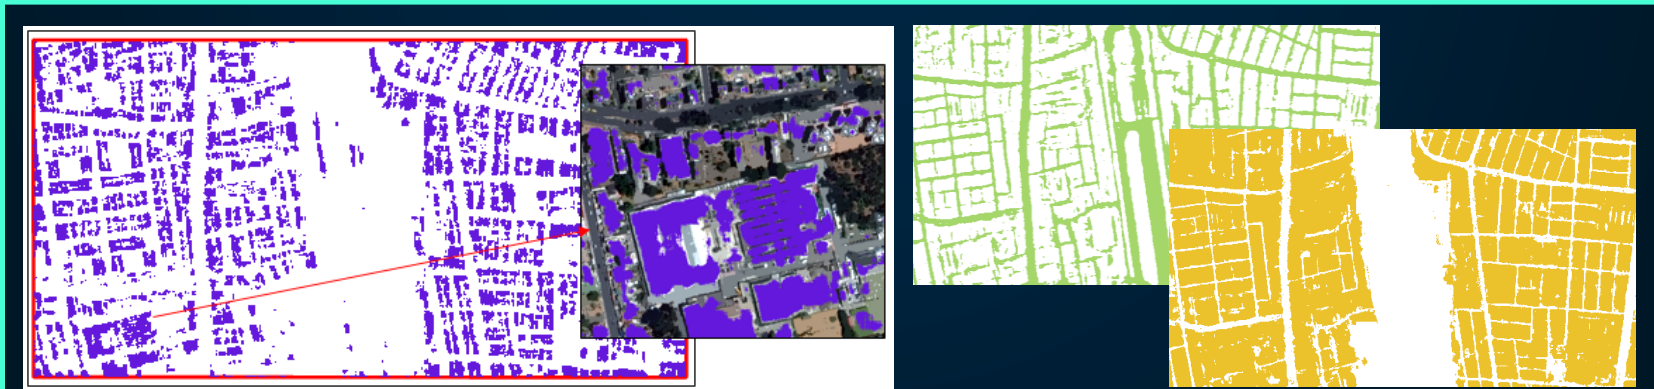


07 RESULTADOS

Resultados del proceso de segmentación



Resultados del proceso de entrenamiento



07 RESULTADOS

Resultados de tiempo de ejecución del proceso de entrenamiento y clasificación

	Épocas	Tipo de modelo	Backbone Model	Tiempo de Procesamiento Train Model	Épocas recorridas	Tiempo de Procesamiento Classify Pixels Using Deep Learning
Edificaciones	100	U-Net	ResNet-34	0:07:15	28	0:10:05
	200	BDCN Edge Detector	ResNet-34	0:09:41	45	0:25:01
	200	U-Net	ResNet-152	2:41:56	34	1:02:10
	200	BDCN Edge Detector	ResNet-152	2:26:31	46	1:02:37
	5	U-Net	ResNet-152	0:28:44	5	0:12:15
Vías	200	BDCN Edge Detector	ResNet-34	0:09:25	24	0:29:01
	200	U-Net	ResNet-152	4:48:31	52	1:15:10
	200	BDCN Edge Detector	ResNet-152	2:52:14	43	1:02:37
Manzanas	200	U-Net	ResNet-34	0:27:32	21	0:21:09
	200	BDCN Edge Detector	ResNet-34	0:27:57	14	0:39:01
	200	U-Net	ResNet-152	2:36:07	27	1:07:44
	200	BDCN Edge Detector	ResNet-152	1:15:20	32	0:47:36

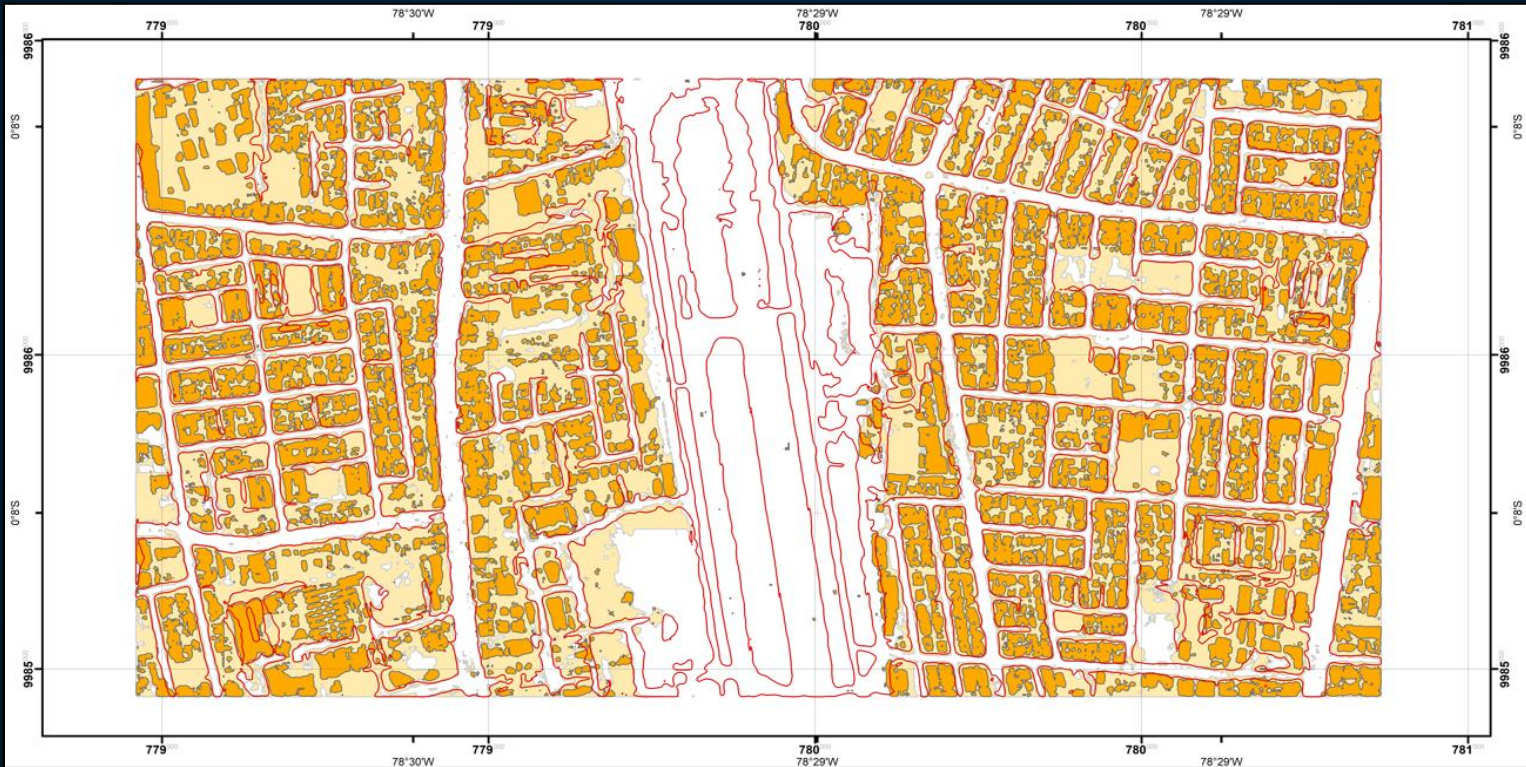
07 RESULTADOS

Resultados del proceso de generalización



07 RESULTADOS

Cartografía por Deep Learning



RESULTADOS DE LA GENERACIÓN
DE CARTOGRAFÍA POR DEEP LEARNING

AGOSTO 2022


07 RESULTADOS

Resultados del proceso de evaluación de exactitud posicional de la cartografía digitalizada y por deep learning

Cartografía digitalizada

Estadística	Digitalización
Dist. Min (m)	0.134
Dist. Max (m)	1.430
Media (m)	0.773
Desv. Est. (m)	0.334
Exactitud NSSDA r al 95% (m)	1.444
Exactitud IGM r al 90% (m)	1.266

Cartografía por Deep Learning



Puntos	Distancias mínimas
1	2.80
5	2.52
6	1.87
17	4.78
20	6.35

07 RESULTADOS

Cuadro	Omisión digitalización	Comisión digitalización	Omisión Deep Learning	Comisión Deep Learning
1	NO	NO	SI	NO
2	NO	NO	NO	NO
3	NO	NO	NO	SI
4	NO	NO	NO	SI
5	NO	NO	NO	SI
6	NO	NO	NO	SI
7	NO	NO	SI	NO
8	NO	NO	SI	SI
9	NO	NO	SI	SI
10	NO	NO	NO	SI
11	NO	NO	SI	SI
12	NO	NO	SI	NO
13	NO	NO	SI	SI
14	NO	NO	SI	SI
15	NO	NO	NO	SI
16	NO	NO	SI	SI
17	NO	NO	SI	SI
18	NO	NO	NO	SI
19	NO	NO	NO	SI
20	NO	NO	SI	SI

07 RESULTADOS

Resultados del proceso de consistencia lógica

Digitalización	Revisión	Deep Learning	Revisión
tierra_sin_vegetacion_a	X	tierra_sin_vegetacion_a	-
arbol_p	X	arbol_p	-
manzana_a	X	manzana_a	X
edificio_a	X	edificio_a	X
cancha_a	X	cancha_a	-
parterre_a	X	parterre_a	-
via_ruta_a	X	via_ruta_a	X
via_ruta_l	X	via_ruta_l	-

Resultados del proceso de exactitud posicional

Estadística	Digitalización
Dist. Min (m)	0.134
Dist. Max (m)	1.430
Dist. Prom (m)	0.773
Desv. Est. (m)	0.334
RMSE _x (m)	0.562
RMSE _y (m)	0.618
RMSE _r (m)	0.835
Exactitud NSSDA r al 95% (m)	1.444
Exactitud IGM r al 90% (m)	1.266

07 RESULTADOS


Ortoimágenes															
Años	2014 (100km ²)					2016 (25km ²)					2018 (25km ²)				
# puntos	42	30	21	9	7	42	30	21	9	7	42	30	21	9	7
Dist. mín [m]	0.034	0.066	0.061	0.125	0.149	0.183	0.178	0.169	0.106	0.131	0.728	0.725	0.828	0.725	0.059
Dist. máx [m]	1.920	2.175	2.047	1.941	1.996	2.083	2.103	2.104	2.032	2.029	1.848	2.494	2.109	2.076	2.448
Dist. prom [m]	0.445	0.450	0.451	0.476	0.466	0.561	0.536	0.542	0.520	0.527	1.240	1.314	1.262	1.329	1.331
Desv. est [m]	0.415	0.458	0.430	0.429	0.419	0.412	0.424	0.422	0.414	0.400	0.310	0.454	0.360	0.384	0.517
RMSE _x [m]	0.459	0.547	0.477	0.497	0.474	0.353	0.355	0.354	0.351	0.348	0.733	0.723	0.660	0.711	0.728
RMSE _y [m]	0.389	0.320	0.390	0.393	0.400	0.593	0.576	0.582	0.556	0.556	1.045	1.183	1.132	1.184	1.223
RMSE _z [m]	0.994	0.884	0.989	2.083	2.211	0.555	0.384	0.502	0.476	0.517	0.850	0.797	0.763	0.748	0.995
Exactitud NSSDA r al 95% [m]	1.037	1.061	1.060	1.088	1.068	1.158	1.139	1.144	1.110	1.106	2.175	2.332	2.193	2.318	2.387
Exactitud IGM r al 90% [m]	0.910	0.931	0.930	0.955	0.937	1.015	0.999	1.004	0.973	0.970	1.907	2.045	1.923	2.033	2.093
Modelos Digitales de Superficie															
Exactitud NSSDA v al 95% [m]	1.949	1.732	1.938	1.063	1.128	1.088	0.753	0.983	0.932	1.014	1.666	1.561	1.496	1.465	1.951

08 CONCLUSIONES

- Luego de ortorrectificar las imágenes satelitales de pares estereoscópicos con diferente nadir a partir de ERDAS Imagine, se concluye que con el método WorldView RPC se obtienen mejores resultados de calidad estadística y exactitud posicional en las imágenes WorldView 2 y 3 que con el método Polynomial Based Pushbroom; además, se evidenció en las áreas de estudio de 100km² y 25km², que son suficientes entre 7 y 9 GCP debido a la topografía del terreno.
- Las ortoimágenes analizadas en el área de estudio (Sector Centro-Norte del DMQ) de los años 2014 y 2016, sirven como producto base para escala 1:5000 en la precisión horizontal, acorde a las evaluaciones aplicando la estadística clásica y las normativas IGM y NSSDA con niveles de confianza de 90% y 95% respectivamente. En cuanto a la precisión vertical de los MDS el producto 2016 cumple con un nivel de confianza del 95% que no supera 1.25m.
- Se generó cartografía por los métodos: interpretación / digitalización y deep learning, encontrando que la generación de cartografía por el primer método (digitalización) es en cuanto a calidad, en base a la norma ISO 19157, mejor; además, se concluye preliminarmente, en base al área analizada de 200ha que, sí se puede generar cartografía digitalizada cumpliendo con la precisión horizontal y las normativas antes señaladas para escala 1:5000, utilizando como base ortoimágenes con mayor o igual resolución espacial a 0.40m y con nadir igual o inferior a 13.1°.
- Debido a los errores gráficos evidenciados en: asociación de objetos similares como edificaciones continuas o muy próximas; agrupación y no discriminación en lotes, canchas y vías, se concluye que para la escala 1:5000, con deep learning en el software utilizado, no se puede generar el mismo tipo de cartografía, con todos sus objetos, que elabora el IGM.

08 RECOMENDACIONES

- Se recomienda realizar pruebas con los productos obtenidos por deep learning para escalas 1:7000 o menores en zonas urbanas y rurales, experimentar con la extracción de cartografía de puntos y líneas con elementos como árboles y vías respectivamente; realizando pruebas con los valores de densidad espectral, espacial y tamaño mínimo de pixel.
- Leer la Guía del Modelo del Sensor que se encuentra en la página oficial de Hexagon, la misma que muestra los requerimientos necesarios para escoger el método a utilizar en la ortorrectificación, y revisar los metadatos de las imágenes satelitales WorldView 2-3 en los archivos .IMD, los cuales indican el preprocesamiento realizado en las imágenes.



**GRACIAS
POR SU
ATENCIÓN**





UNIVERSIDAD DE LAS
FUERZAS ARMADAS "ESPE"



DEPARTAMENTO DE CIENCIAS DE
LA TIERRA Y DE LA
CONSTRUCCIÓN



INGENIERÍA
GEOGRÁFICA Y DEL
MEDIO AMBIENTE

DEPARTAMENTO DE CIENCIAS DE LA TIERRA Y DE LA CONSTRUCCIÓN

INGENIERÍA GEOGRÁFICA Y DEL MEDIO AMBIENTE

“Generación de ortoimágenes de diferente nadir con pares estereoscópicos satelitales Worldview, y cartografía con Deep Learning a escala 1:5000 en el norte del DMQ”

Autores

Carrasco Puga, Glenda Gisela
Moreno Carrillo, Daniela Alejandra

Director del proyecto

Ing. Kirby Powney, Eduardo

Docente evaluador

Ing. Padilla Almeida, Oswaldo PhD

Director del carrera

Ing. Robayo Nieto, Alexander Msc.

Secretaria académica

Ab. Benavides Guzmán, Michelle

AGOSTO 2022