



**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**

Carrasco Puga, Glenda Gisela y Moreno Carrillo, Daniela Alejandra

Departamento de Ciencias de la Tierra y de la Construcción

Carrera de Ingeniería Geográfica y de Medio Ambiente

Trabajo de titulación, previo a la obtención del título de Ingeniero Geógrafo y de Medio  
Ambiente

Ing. Kirby Powney, Eduardo Patricio, MSc

8 de septiembre de 2022



TESIS\_CARRASCO\_MORENO\_CAP1-5.pdf

Scanned on: 18:18 August 11, 2022 UTC



Overall Similarity Score



Results Found



Total Words in Text

Identical Words	87
Words with Minor Changes	1
Paraphrased Words	9
Omitted Words	3604



Website | Education | Businesses



**Departamento de Ciencias de la Tierra y de la Construcción**  
**Carrera de Ingeniería Geográfica y del Medio Ambiente**

**Certificación**

Certifico que el trabajo de titulación: **“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”** fue realizado por las señoritas **Carrasco Puga, Glenda Gisela y Moreno Carrillo Daniela Alejandra**; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

**Sangolquí, 26 de Agosto de 2022**

Firma:



Firmado electrónicamente por:  
**EDUARDO  
PATRICIO KIRBY  
POWNEY**

.....  
**Ing. Kirby Powney, Eduardo Patricio, MSc**

C. C.: 0102611811



**Departamento de Ciencias de la Tierra y de la Construcción**  
**Carrera de Ingeniería Geográfica y del Medio Ambiente**

**Responsabilidad de Autoría**

Nosotras, **Carrasco Puga, Glenda Gisela y Moreno Carrillo Daniela Alejandra**, con cédulas de ciudadanía n° 1501093619 y n° 0605145903, declaramos que el contenido, ideas y criterios del trabajo de titulación: **"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"** es de nuestra autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

**Sangolquí, 26 de Agosto de 2022**

**Carrasco Puga, Glenda Gisela**

C.C.: 1501093619

**Moreno Carrillo, Daniela Alejandra**

C.C.: 0605145903



**Departamento de Ciencias de la Tierra y de la Construcción**

**Carrera de Ingeniería Geográfica y del Medio Ambiente**

**Autorización de Publicación**

Nosotras **Carrasco Puga, Glenda Gisela** y **Moreno Carrillo Daniela Alejandra**, con cédulas de ciudadanía n° 1501093619 y n° 0605145903, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **"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"** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad.

**Sangolquí, 26 de Agosto de 2022**

**Carrasco Puga, Glenda Gisela**

C.C.: 1501093619

**Moreno Carrillo, Daniela Alejandra**

C.C.: 0605145903

## Dedicatoria

*Dedico este logro a mi familia, que ha sido el pilar fundamental en mi vida.*

*A mis padres Ángel y Teresa por ser mi guía, mi apoyo incondicional a lo largo de mi vida y sobretodo en mi carrera universitaria, han sido ejemplo de fuerza y superación, ya que ante todo adversidad presentada han sabido salir adelante, su amor y consejos han sido importantes para cumplir este sueño. Los amo.*

*A mis abuelitos maternos, Nimia y Rafael por ser el pilar de la familia, por darme todo su amor y apoyo incondicional, han sido mi inspiración para culminar esta etapa de mi vida.*

*A mis hermanos Jeison y Carla, por ser esos compañeros de vida que nunca me han dejado sola y siempre han estado junto a mí con sus consejos y cariño.*

*A mis sobrinos, Sofía, Ian y Xander por ser alegría en mi vida y demostrarme que el amor puro y sincero existe, que este logro los haga sentir orgullosos.*

*A mi cookie, que me ha enseñado lo que es ser incondicional y la responsabilidad, ha llenado mi corazón de amor.*

*A todas las personas que de una u otra manera aportaron en mi vida para llegar.*

**Gise**

## Dedicatoria

“Las raíces de los verdaderos logros residen en la voluntad de convertirse en lo mejor que puedas llegar a ser” Harold Taylor.

El haber culminado un paso tan importante en mi vida se los debo a mis padres Rosario y Pablo, es por este motivo que este logro se los dedico, con todo el amor y cariño, gracias a ustedes he entendido el valor de la perseverancia, “el que persevera alcanza”, espero que siempre estén orgullosos de mí y con sus enseñanzas sabré superar cada adversidad en mi camino.

A mi abuelita Emmita quien a pesar de la distancia ha sido un pilar fundamental durante mi etapa de estudiante y lo seguirá siendo durante mi vida profesional, con sus consejos y cuidados me ha sabido guiar para no desfallecer.

A mi abuelito Juanito quien a pesar de no haberme visto culminar este logro, sé que se está muy orgulloso de mí en el cielo, gracias a él y a su bondad me permitieron valorar el tiempo en familia, le llevaré por siempre en mi alma y corazón.

A mi hermana Karlita quien me acompañaba durante sus vacaciones del colegio, te dedico esta tesis porque me has enseñado que todo esfuerzo tiene su recompensa, espero siempre servirte de ejemplo durante toda tu carrera.

A todos quienes me han aportado con sus conocimientos, enseñanzas y ánimo.

***Dani***

## **Agradecimiento**

*A mis padres, Ángel y Teresa por haber estado a mi lado en todas las etapas de mi vida, por esas llamadas que me llenaban de fuerza para seguir adelante y no darme por vencida, por los valores y principios que me inculcaron para llegar a ser la persona que soy ahora.*

*A mis abuelitos, gracias por sus oraciones y consejos, que han sido vitales para llegar hasta este punto.*

*A mis hermanos, que fueron mi apoyo desde la infancia, gracias por aconsejarme, no dejarme sola y por cuidarme en todo momento, su ayuda fue de importancia para concluir esta etapa.*

*A mis sobrinos, por ser ese motorcito para mi vida, todo lo que logre, es por y para ustedes.*

*A mis tutores, Ing. Eduardo Kirby e Ing. Oswaldo Padilla, por la paciencia y los conocimientos que a lo largo de la carrera pudieron impartir, han sido guías incondicionales para culminar este proyecto, gracias por los consejos.*

*A mi amiga y compañera de tesis Dani, el esfuerzo puesto en este trabajo de titulación se ve reflejado, gracias por apoyarme en los buenos momentos pero sobre todo en los malos, a pesar de todas las adversidades presentadas se logró este sueño*

*A mis amigas Ellie, Dey y Karlita, gracias por apoyarme en todo momento, nunca olvidaré que fueron mi fuerza en momentos que no podía más.*

*Un agradecimiento especial a mis personas favoritas Cris y Nico, ustedes se convirtieron en mi familia y sé que esta amistad es para siempre, gracias por escucharme y siempre estar junto a mí.*

*Y finalmente a todas aquellas personas que pasaron por mi vida, familiares y amigos, gracias por ser parte de este camino, todo lo bonito queda en mi corazón.*

**Gise**

## Agradecimiento

Agradezco principalmente a Dios, a quien acudí en buenos y malos momentos para contarle como me sentía durante cada paso en la carrera, le agradezco por permitirme conocer a personas maravillosas y a darme guía durante los malos momentos.

Agradezco a cada miembro de mi familia, confiaron en mí y me supieron guiar en cada paso de la carrera, me aconsejaron y brindaron apoyo en todo momento. A mi mami Rosario quien con sus llamadas nocturnas y duernas me ayudaba a no decaer, para seguir cumpliendo con la meta, a mi papi Pablo quien me iba a visitar los fines de semana y con quien compartía siempre palabras de aliento, a mi hermana Karla quien sacrificaba sus vacaciones para acompañarme mientras estudiaba, a mi abuelita Emmita y abuelito Juanito gracias a ustedes pude concretar un sueño, sus llamadas me alegraban todas las noches; gracias querida familia.

A la Universidad de las Fuerzas Armadas y los excelentes docentes de la carrera de Ingeniería Geográfica y del Medio Ambiente quienes han contribuido en mi formación académica, llevaré conmigo siempre sus enseñanzas, en especial al Ing. Eduardo Kirby quien me ha compartido su conocimiento y me ha brindado la confianza para poder realizar este trabajo de titulación, agradezco cada sacrificio en vacaciones ya que me ha permitido llenarme de conocimiento, espero seguir siempre su ejemplo.

A Geoint quienes me han abierto la puerta para realizar este trabajo de titulación con la guía de Oswaldo, Sofía, Omar y Óscar he podido salir adelante durante las adversidades presentadas, gracias por confiar en mí, siempre estaré agradecida.

A mi amiga y coautora Gise, con quien llevo más de 5 años de amistad, su paciencia y cariño me han permitido culminar este paso y me siento muy contenta de que hayamos compartido esta gran aventura juntas, a pesar de todas las adversidades hemos sabido solucionarlas y apoyarnos mutuamente.

A Erick quien ha sido un gran apoyo durante mi carrera universitaria, gracias por no dejarme desfallecer ni un momento por darme el ánimo que necesitaba cuando no podía más, siempre estuviste motivándome en cada adversidad, gracias por estar en todos mis logros.

A mis amigas Deysi, Ellie y Karlita, sus risas, noches de estudio, aventuras y llantos dieron color a mi vida universitaria, gracias a ustedes pude superar esta difícil etapa, el reunirnos en la biblioteca a reírnos, ir a almorzar juntas y darnos ánimo al estudiar han sido los mejores momentos de mi trayectoria.

A mi Luka quien fue parte en el momento final del desarrollo de mi tesis y todos quienes me dieron ánimo, guía y consejos, muchas gracias.

**Dani**

## Índice de contenido

Dedicatoria .....	5
Dedicatoria .....	7
Agradecimiento .....	8
Agradecimiento .....	9
Índice de contenido .....	10
Índice de Tablas .....	15
Índice de Figuras .....	17
Resumen .....	20
Abstract .....	21
Capítulo I .....	22
Aspectos Generales .....	22
Planteamiento del Problema de Investigación .....	22
Antecedentes .....	24
Justificación e Importancia .....	27
Objetivos .....	29
<i>Objetivo General</i> .....	29
<i>Objetivos Específicos</i> .....	29
Descripción General del Trabajo .....	30
Hipótesis .....	31
Metas .....	31
Capítulo II .....	33
Conceptos y Generalidades .....	33
Visión estereoscópica .....	33
Imágenes satelitales estereoscópicas .....	33
Resoluciones satelitales .....	34
<i>Resolución espacial</i> .....	34
<i>Resolución temporal</i> .....	35
<i>Resolución angular</i> .....	36
Geometría Epipolar .....	36
<i>Plano epipolar</i> .....	37
<i>Línea epipolar</i> .....	37
Ortoimagen .....	37

Ortorrectificación.....	37
WorldView RPC .....	38
Polynomial based Pushbroom.....	38
Cartografía .....	38
<i>Extracción de cartografía</i> .....	38
<i>Extracción manual</i> .....	39
Digitalización.....	39
Topología .....	39
Reglas topológicas .....	39
Extracción automática .....	42
Heterogeneidad espectral .....	42
Deep Learning .....	42
Segmentación.....	43
Modelo U-Net.....	44
Modelo BDCN.....	44
Épocas .....	44
Generalización .....	44
Herramientas de generalización.....	45
Cartografía planimétrica .....	46
Satélite WorldView-2 .....	46
Satélite WorldView-3 .....	46
Image Metadata Data (IMD).....	47
Tile Map File .....	47
Estaciones de monitoreo .....	47
Métodos de posicionamiento.....	48
<i>Fast Static</i> .....	48
<i>Protocolo NTRIP</i> .....	49
Puntos de control.....	49
Alturas elipsoidales.....	49
Rational Polynomial Coefficients (RPC).....	50
Modelo Digital de Superficie (MDS) .....	50
Nadir.....	50
Exactitud posicional .....	50
Precisión .....	51
Control de calidad.....	51

<i>Norma ISO 19157:2013</i> .....	51
<i>Norma NSSDA</i> .....	51
<i>Tamaño de la muestra en exactitud posicional</i> .....	53
<i>Exactitud posicional de acuerdo al Instituto Geográfico Militar (IGM)</i> .....	54
<i>Precisiones planimétrica y altimétrica según el Instituto Geográfico Militar</i> .....	54
<i>Precisión de los puntos de control (GCP) según el Instituto Geográfico Militar</i> .....	54
Estadísticos.....	55
<i>Media</i> .....	55
<i>Desviación estándar</i> .....	55
<i>Nivel de confianza</i> .....	55
<i>Error medio cuadrático (RMS)</i> .....	55
Capítulo III.....	56
Metodología .....	56
Generalidades.....	56
Obtención de información.....	65
<i>Control Terrestre</i> .....	67
<i>Planeación de la ubicación de puntos de control</i> .....	69
<i>Reconocimiento en campo</i> .....	73
<i>Toma de puntos de apoyo (GCP)</i> .....	73
<i>Toma de puntos de validación de exactitud posicional</i> .....	73
<i>Evaluación de la precisión de puntos de apoyo (GCP) y puntos de validación de exactitud posicional</i> .....	74
Generación de Ortoimágenes .....	74
<i>Generación de ortoimágenes por aerotriangulación combinada con los Coeficientes Polinomiales Racionales (RPC)</i> .....	74
Orientación Interior RPC .....	75
Orientación exterior RPC.....	76
Generación de MDS por correlación con el modelo RPC .....	78
Generación de la ortoimagen con el modelo RPC .....	78
<i>Generación de ortoimágenes por aerotriangulación Directa</i> .....	79
Orientación interior Aerotriangulación Directa .....	80
Orientación exterior Aerotriangulación Directa .....	81
Marcado de GCP .....	81
Generación MDS por correlación con el modelo Polynomial Based in Pushbroom .....	84
Generación de la ortoimagen con el modelo Polynomial Based in Pushbroom .....	84

Exactitud espacial de los productos derivados del ajuste .....	85
Evaluación exactitud posicional planimétrica normas NSSDA e IGM de las ortoimágenes...	85
Evaluación exactitud posicional altimétrica de los MDS .....	87
Generación de Cartografía .....	89
Generación de Cartografía por Digitalización .....	89
Generación de Cartografía por Deep Learning.....	93
Software utilizado para la generación de Cartografía por Deep Learning .....	93
Requerimientos del sistema para instalar ArcGIS Pro .....	93
Definición de las clases .....	94
Segmentación de imagen.....	96
Extracción de datos de entrenamiento.....	98
Reclasificación de los datos de entrenamiento.....	99
Generalización de los datos de clasificación por Deep Learning .....	105
Exactitud espacial de la cartografía de los procesos de digitalización y Deep Learning.....	107
Evaluación exactitud posicional planimétrica de cartografía digitalizada y por Deep Learning .....	107
Control de calidad de datos en base a la norma ISO 19157 .....	108
<i>Control de Compleción</i> .....	110
<i>Control de Consistencia lógica</i> .....	110
<i>Control de Exactitud posicional según la estadística normativa</i> .....	111
Capítulo IV .....	113
Resultados .....	113
Resultados del control terrestre.....	113
<i>Resultados de la toma de puntos de apoyo (GCP)</i> .....	113
<i>Resultados de la evaluación de la precisión de puntos de apoyo (GCP)</i> .....	119
<i>Resultados de puntos de validación de exactitud posicional</i> .....	119
<i>Resultados de la evaluación de la precisión de puntos de evaluación de la exactitud posicional</i> .....	123
Resultados de la generación de ortoimágenes.....	124
<i>Resultados de la Aerotriangulación</i> .....	124
<i>Resultados del reporte de Aerotriangulación</i> .....	125
<i>Resultados de la generación MDS por correlación con el modelo RPC y el modelo Polynomial Based in Pushbroom</i> .....	126
<i>Resultados de ortoimágenes por el modelo de Aerotriangulación RPC</i> .....	127
<i>Resultados de ortoimágenes por el método de Aerotriangulación Directa</i> .....	128

Resultados de la exactitud espacial por estadística clásica de los productos derivados del ajuste.....	130
Resultados de evaluación exactitud posicional planimétrica con estadística normativa de las ortoimágenes .....	155
Evaluación exactitud posicional altimétrica del MDS.....	157
Resultado de topología pasada en la cartografía digitalizada.....	158
Resultados de la segmentación dentro del proceso de Deep Learning.....	160
Resultados de extracción de datos de entrenamiento.....	162
Resultados del entrenamiento del modelo.....	163
Resultados de la clasificación de píxeles mediante Deep Learning .....	166
Resultados del proceso de generalización .....	175
Resultado de la generación de cartografía por Deep Learning.....	179
Resultados de la exactitud espacial de los productos derivados de los procesos de digitalización y deep learning .....	180
<i>Evaluación de exactitud posicional de la cartografía Digitalizada</i> .....	180
<i>Evaluación de exactitud posicional de la cartografía Deep Learning</i> .....	182
Resultados del control de calidad aplicando la Norma ISO 19157 .....	183
<i>Resultados de Control de Compleción</i> .....	183
<i>Resultados de Control de Consistencia Lógica</i> .....	185
<i>Resultados de Control de exactitud posicional</i> .....	186
Capítulo V .....	189
Conclusiones y Recomendaciones .....	189
Conclusiones .....	189
Recomendaciones .....	190
Bibliografía .....	192

## Índice de Tablas

<b>Tabla 1</b> Reglas topológicas en ArcGIS .....	40
<b>Tabla 2</b> Herramientas de generalización de ESRI .....	45
<b>Tabla 3</b> Tamaño de la muestra de puntos en función al área de estudio .....	53
<b>Tabla 4</b> Especificaciones de las imágenes satelitales estereoscópicas .....	66
<b>Tabla 5</b> Muestras de medidas.....	68
<b>Tabla 6</b> Elementos digitalizados en el proceso de generación de cartografía .....	90
<b>Tabla 7</b> Requisitos de hardware para instalar ArcGIS Pro.....	93
<b>Tabla 8</b> Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2014.....	113
<b>Tabla 9</b> Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2016.....	115
<b>Tabla 10</b> Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2018...	117
<b>Tabla 11</b> Resultados de las precisiones de puntos de apoyo de los años 2014, 2016 y 2018.	119
<b>Tabla 12</b> Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2014 .....	120
<b>Tabla 13</b> Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2016 .....	121
<b>Tabla 14</b> Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2018 .....	122
<b>Tabla 15</b> Resultados de las precisiones de puntos de verificación de los años 2014, 2016 y 2018. ....	123
<b>Tabla 16</b> Resultado de la Aerotriangulación para cada modelo .....	124
<b>Tabla 17</b> Resultados de media, desviación estándar, máximo y mínimo de las ortoimágenes año 2016 .....	130
<b>Tabla 18</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 42 GCP .....	132
<b>Tabla 19</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 30 GCP .....	133
<b>Tabla 20</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 21 GCP .....	134
<b>Tabla 21</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 9 GCP .....	135
<b>Tabla 22</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 7 GCP .....	137
<b>Tabla 23</b> Resultados de los estadísticos clásicos ortoimágenes del año 2014.....	138
<b>Tabla 24</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 42 GCP .....	140

<b>Tabla 25</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 30 GCP .....	141
<b>Tabla 26</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 21 GCP .....	142
<b>Tabla 27</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 9 GCP .....	144
<b>Tabla 28</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 7 GCP .....	145
<b>Tabla 29</b> Resultados de los estadísticos clásicos ortoimágenes del año 2016.....	146
<b>Tabla 30</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 42 GCP .....	148
<b>Tabla 31</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 30 GCP .....	149
<b>Tabla 32</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 21 GCP .....	151
<b>Tabla 33</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 9 GCP .....	152
<b>Tabla 34</b> Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 7 GCP .....	153
<b>Tabla 35</b> Resultados de los estadísticos clásicos ortoimágenes del año 2018.....	154
<b>Tabla 36</b> Resultados estadística normativa de las ortoimágenes (exactitud planimétrica) .....	155
<b>Tabla 37</b> Resultados estadísticos MDS (exactitud altimétrica) .....	157
<b>Tabla 38</b> Resultados de entrenamiento del modelo para edificaciones .....	163
<b>Tabla 39</b> Resultados de entrenamiento del modelo para vías.....	164
<b>Tabla 40</b> Resultados de entrenamiento del modelo para manzanas.....	165
<b>Tabla 41</b> Resultados de entrenamiento y clasificación del modelo para edificaciones, vías y manzanas.....	174
<b>Tabla 42</b> Resultados exactitud posicional de la cartografía Digitalizada .....	181
<b>Tabla 43</b> Distancias mínimas del punto de referencia y homólogo en la cartografía por deep learning .....	183
<b>Tabla 44</b> Resultados de control de compleción.....	184
<b>Tabla 45</b> Resultados de Control de Consistencia Lógica.....	185
<b>Tabla 46</b> Resultados exactitud posicional de la cartografía .....	186
<b>Tabla 47</b> Resultados exactitud posicional planimétrica para ortoimágenes y altimétrica en Modelos Digitales de Superficie .....	188

## Índice de Figuras

<b>Figura 1</b> Zona de estudio de la investigación – Cantón Quito .....	31
<b>Figura 2</b> Resolución espacial de diferentes satélites .....	35
<b>Figura 3</b> Resolución temporal .....	35
<b>Figura 4</b> Resolución angular .....	36
<b>Figura 5</b> Geometría Epipolar .....	36
<b>Figura 6</b> Diferencias entre los métodos de segmentación de imágenes.....	43
<b>Figura 7</b> Flujograma general de la metodología seguida.....	57
<b>Figura 8</b> Revisión de georreferenciación.....	67
<b>Figura 9</b> Propuesta de distribución de puntos de apoyo (GCP) par estéreo del año 2014 .....	69
<b>Figura 10</b> Propuesta de distribución de puntos de apoyo (GCP) par estéreo del año 2016 .....	70
<b>Figura 11</b> Propuesta de distribución de puntos de apoyo (GCP) par estéreo del año 2018 .....	70
<b>Figura 12</b> Distribución de puntos de validación de exactitud posicional par estéreo del año 2014 .....	71
<b>Figura 13</b> Distribución de puntos de validación de exactitud posicional par estéreo del año 2016 .....	71
<b>Figura 14</b> Distribución de puntos de validación de exactitud posicional par estéreo del año 2018 .....	72
<b>Figura 15</b> Distribución de puntos de validación de exactitud posicional para la cartografía.....	72
<b>Figura 16</b> Configuración del modelo del sensor y sistema de referencia.....	75
<b>Figura 17</b> Orientación interior del sensor WorldView.....	76
<b>Figura 18</b> Entorno de trabajo para colocar puntos de control (GCP) .....	76
<b>Figura 19</b> Herramienta Compute image coordinates from the ground points .....	77
<b>Figura 20</b> Ubicación de los puntos importados .....	77
<b>Figura 21</b> Parámetros de obtención de MDS .....	78
<b>Figura 22</b> Parámetros para la ortorrectificación de la imagen .....	79
<b>Figura 23</b> Configuración del modelo del sensor.....	80
<b>Figura 24</b> Orientación interior y creación de parámetros del sensor WorlView .....	80
<b>Figura 25</b> Entorno de trabajo para colocar puntos de control (GCP) .....	81
<b>Figura 26</b> Marcado de puntos de apoyo (GCP) .....	82
<b>Figura 27</b> Importación de coordenadas de referencia .....	82
<b>Figura 28</b> Modificación de los pesos de cada punto en la Aerotriangulación .....	83
<b>Figura 29</b> Aerotriangulación de la ortoimagen modelo Polynomial Based in Pushbroom .....	83
<b>Figura 30</b> Parámetros para obtención de MDS.....	84

<b>Figura 31</b> Parámetros para la ortorrectificación de la imagen .....	85
<b>Figura 32</b> Valores de altura del MDS .....	88
<b>Figura 33</b> Creación de las reglas de topología.....	92
<b>Figura 34</b> Muestra de polígonos de vías para modelo de entrenamiento .....	95
<b>Figura 35</b> Muestra de polígonos de manzanas para modelo de entrenamiento .....	95
<b>Figura 36</b> Muestra de polígonos de edificaciones para modelo de entrenamiento.....	96
<b>Figura 37</b> Herramienta de segmentación de la imagen .....	97
<b>Figura 38</b> Exportar ráster de segmentación .....	98
<b>Figura 39</b> Extracción de datos de entrenamiento – Geoprocesamiento de polígono a ráste ....	99
<b>Figura 40</b> Reclasificación de los datos de entrenamiento .....	100
<b>Figura 41</b> Propiedades del dataset ráster .....	101
<b>Figura 42</b> Modelos de entrenamiento.....	102
<b>Figura 43</b> Entrenamiento del modelo .....	104
<b>Figura 44</b> Clasificación de píxeles para identificación de edificios .....	105
<b>Figura 45</b> Herramienta de generalización en Model Builder .....	106
<b>Figura 46</b> Norma ISO 19157, elementos aplicables .....	109
<b>Figura 47</b> Distribución de grilla para control de compleción .....	110
<b>Figura 48</b> Consistencia de dominio .....	111
<b>Figura 49</b> Reporte de Aerotriangulación.....	126
<b>Figura 50</b> MDS e informe de calidad .....	127
<b>Figura 51</b> Ortoimagen con 42 GCP del año 2014.....	128
<b>Figura 52</b> Ortoimagen con 42 GCP del año 2018.....	129
<b>Figura 53</b> Desplazamientos de los puntos de referencia y sus homólogos en la ortoimagen 2014 .....	131
<b>Figura 54</b> Desplazamientos de los puntos de referencia y sus homólogos en las ortoimágenes 2016 .....	139
<b>Figura 55</b> Desplazamientos de los puntos de referencia y sus homólogos en las ortoimágenes 2018 .....	147
<b>Figura 56</b> Mapa de cartografía por digitalización .....	159
<b>Figura 57</b> Catalogación del Dataset canchas.....	160
<b>Figura 58</b> Ejemplo de segmentaciones de la ortoimagen.....	161
<b>Figura 59</b> Resultados de extracción de datos de entrenamiento .....	162
<b>Figura 60</b> Resultados de la clasificación de píxeles mediante deep learning - edificaciones..	167
<b>Figura 61</b> Resultados de la clasificación de píxeles mediante deep learning - vías .....	170
<b>Figura 62</b> Resultados de la clasificación de píxeles mediante deep learning - manzana.....	172

<b>Figura 63</b> Resultados del proceso de generalización para edificaciones.....	176
<b>Figura 64</b> Resultados del proceso de generalización para vías .....	177
<b>Figura 65</b> Resultados del proceso de generalización para vías .....	178
<b>Figura 66</b> Mapa de cartografía por Deep Learning .....	180
<b>Figura 67</b> Desplazamiento del punto de referencia y homólogo en la cartografía digitalizada	181
<b>Figura 68</b> Desplazamiento del punto de referencia y homólogo en la cartografía por deep learning .....	182

## Resumen

El desarrollo de nuevas tecnologías de información geoespacial, tales como Deep Learning, han permitido optimizar tiempo de extracción de cartografía, reducir costos y el personal de trabajo; mientras que, la elaboración de cartografía por métodos tradicionales es un proceso que demanda tiempo y recursos como: personal capacitado, hardware y software. Es así que en este proyecto surge la necesidad de 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 Distrito Metropolitano de Quito (DMQ) que servirán como una técnica alternativa para la obtención de insumos geoespaciales. En base al desarrollo se obtiene que, el mejor método para generar ortoimágenes es, el modelo el base a los coeficientes polinomiales racionales, con una cantidad entre 7 y 9 GCP en la zona de estudio. Los resultados obtenidos del proyecto fueron varias ortoimágenes, en las cuales las generadas del WorldView-3 de 0.40m de resolución espacial, con nadir de 13.1° y un área de 100km<sup>2</sup>, cumplen con la precisión horizontal para escala 1:5000, con un nivel de confianza entre 90%-95%. La cartografía generada por el método de interpretación / digitalización en un área de 200ha de una zona plana si cumple con la precisión horizontal; mientras que, por el método Deep Learning no, cabe recalcar que, la cartografía automatizada es muy útil en la extracción de vías de similar material y en manzanas cuando se aplican grandes muestras (en extensión) para el entrenamiento del modelo.

*Palabras clave:* ortoimágenes, correlación, cartografía, Deep Learning

### **Abstract**

The development of new geospatial information technologies, such as Deep Learning, have made it possible to improve cartography extraction time, as well as reduce costs and staff; whereas, the elaboration of cartography by traditional methods, is a process that demands time and several resources such as: trained personnel and the usage of hardware and software. Thus, in this project there is a need to produce orthoimages of different nadir with WorldView satellite stereoscopic pairs by correlation, and mapping with Deep Learning at a scale of 1:5000 in the north of the Metropolitan District of Quito (MDQ) which will work as an alternative technique to obtain geospatial supplies. Based on the development, it is obtained that the best method to produce orthoimages is the model based on rational polynomial coefficients, with an amount between 7 and 9 GCP applied to the study area. The results obtained from the project, were several orthoimages, in which those generated from WorldView-3 of 0.40m spatial resolution, with a nadir of  $13.1^\circ$  and an area of  $100\text{km}^2$ , comply with the horizontal precision for a scale of 1:5000, with a confidence level between 90% - 95%. The cartography formed by the interpretation/digitization method, in an area of 200ha of a flat territory, does comply with the horizontal accuracy; meanwhile the Deep Learning method does not. It should be noted that automated cartography is highly useful when it comes to extracting roads of similar material and in blocks, when large samples (in extension), are applied for model training.

*Keywords:* orthoimages, correlation, cartography, Deep Learning

## Capítulo I

### Aspectos Generales

El presente capítulo detalla los aspectos generales relacionados con el proyecto de investigación, como son: el planteamiento del problema, antecedentes, justificación e importancia del proyecto, delimitación del área de estudio, objetivos tanto general como específicos y metas.

#### Planteamiento del Problema de Investigación

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, esta información debe ser veraz y poseer un bajo margen de error con la finalidad de poder realizar consultas de información geográfica (Torrent, Muñoz, González, & Rodríguez, 2021). Para generar esta información se utilizan datos vectoriales y ráster, se toma como ejemplo de datos vectoriales a manzanas, edificios, vías, entre otros, mismos que en la actualidad son producidos por operadores que se basan en metodologías tales como digitalización en 2D o por restitución siendo esta una alta inversión de dinero (Höhle, 2021).

La elaboración de cartografía por métodos tradicionales es un proceso que demanda tiempo y recursos tales como: personal capacitado, hardware y software (Jarandilla, 2014). 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, lo cual se considera de suma importancia en la toma de decisiones, en las que se necesita de una pronta respuesta (Batista & Ferman, 2018).

El desarrollo de nuevas tecnologías tales como el Deep Learning han permitido optimizar el tiempo de extracción de cartografía, reducir los costos y el personal de trabajo; esta

tecnología permite generar un modelo de aprendizaje ajustado a las necesidades del usuario y realiza correcciones dentro del proceso (Zefriz, Sebari, Hajji, & Aniba, 2021) tanto a datos bidimensionales como tridimensionales de forma masiva permitiendo al usuario aprovechar al máximo la información dada.

Así también han evolucionado las técnicas de georreferenciación para imágenes satelitales, tales como, la tecnología NTRIP la cual permite realizar correcciones de GPS en tiempo real a través de internet (Zabala, 2018). Los equipos móviles tienen varias limitaciones para poder generar medidas a partir de puntos no conocidos y con grandes distancias entre el receptor base y el móvil (Tierra, Silva, & Leiva, Correcciones diferenciales vía NTRIP para dispositivo móvil con aplicación android, 2015).

En el Ecuador diferentes instituciones y empresas utilizan imágenes satelitales monoscópicas o pares estereoscópicos para la obtención de imágenes ortorrectificadas para lo cual se utiliza fotogrametría, técnica reconocida y utilizada para generar cartografía en diferentes escalas (Morell, Frasquet, & Estornell, 2022); en este sentido, se ha destacado la precisión de la cartografía obtenida a partir de drones versus imágenes satelitales debido tomando en cuenta una mayor resolución espacial por parte de los drones por su menor altura de vuelo, las dos técnicas permiten generar productos 2D y 3D como Ortofotos y Modelos Digitales de Superficie (MDS) respectivamente (Alonso & Chaves, 2021).

Sin embargo cabe mencionar que el uso de imágenes satelitales disminuye la utilización de recursos, esto debido a que los satélites al no estar en contacto directo con el planeta facilitan la toma de grandes volúmenes de información, en zonas de difícil acceso y con condiciones climáticas adversas (Alonso & Chaves, 2021); en Ecuador hoy en día se pueden obtener productos de gran extensión en 2D y 3D con pares estereoscópicos de imágenes satelitales que poseen resoluciones espaciales de 30 cm y alta resolución temporal,

permitiendo generar productos para escala 1:5 000 (Sharawi, 2021), (Gong & Fritsch, 2019) y (Kugler & Went, 2021).

Como se ha mencionado, estos productos contribuyen a la disminución de costos por extensión y la pronta actualización de la información geoespacial, mediante la obtención de imágenes ortorrectificadas para la generación de ortoimágenes de diferente nadir con pares estereoscópicos satelitales WorldView, adicional de cartografía con Deep Learning y digitalización para escala 1:5000 en el norte del DMQ.

Por ello surge la necesidad de elaborar este proyecto que pretende generar cartografía de manera automática en menor tiempo, más económica y de calidad para escala 1:5000 a partir de imágenes satelitales utilizando la tecnología Deep Learning que ayudaría a tener una pronta respuesta en caso de alguna necesidad urgente como en el tema de gestión de riesgos o en la generación de planes de ordenamiento territorial. Con el desarrollo de este proyecto se pretende evaluar la generación de ortoimágenes y cartografía por método tradicional (digitalización) y método automático (Deep Learning), en temas como: tiempos de generación, recursos necesarios, calidad y precisión de los productos obtenidos.

### **Antecedentes**

La necesidad de adquirir grandes volúmenes de información de la superficie terrestre sin entrar en contacto con ella (Garay, 2020), apuntó a un desarrollo de mecanismos que permitieron la rápida obtención de esta, en los últimos años la Teledetección se ha posicionado como una gran herramienta para este fin debido a los avances tecnológicos de los sensores, así también la Teledetección se ha convertido en una opción para realizar diferentes estudios como identificación de zonas sin mapeo, evaluaciones multitemporales de fenómenos naturales, identificación de minería ilegal, apoyo en la predicción meteorológica, entre otros (Cheng, Han, & Lu, 2017) (Pelton, Madry, & Camacho-Lara, 2017) (Torres & Dubovik, 2018).

Los satélites tienen varias ventajas tales como: toma de grandes extensiones de terreno, amplia extensión de datos con diferentes resoluciones espaciales, espectrales y temporales, por lo que a mayor cantidad de bandas existe una mayor resolución espectral (Wang & Zhou, 2018). En 1999, la Teledetección evolucionó con el lanzamiento del primer satélite comercial de alta resolución IKONOS, con una resolución espacial de 4 metros permitiendo realizar mapeo a escala 1:10.000, dentro del ámbito cartográfico la Teledetección en conjunto con los Sistemas de Información Geográfica (SIG) constituyen una herramienta idónea para la generación de cartografía urbana y rural, permitiendo generar y analizar la información catastral, hidrológica, vial, entre otros (Novo, Rodríguez, Acuña, Álvarez, & Lorenzo, 2021).

La cartografía urbana a gran escala ( $\geq 1/5000$ ) se hizo posible desde el espacio; debido a la notable popularidad y demanda de imágenes satelitales de alta resolución, en la actualidad se conocen varios proveedores de contenido geoespacial entre los que se destaca DigitalGlobe al ser la primera empresa que ofrece imágenes con una resolución de 30 cm (DigitalGlobe, 2021), posee una amplia constelación de satélites con una cobertura a nivel global; en septiembre de 2007 se lanzó el satélite WorldView-1 uno de los más versátiles que han volado hasta el momento (Büyüksalih & Jacobsen, 2013).

DigitalGlobe continuó con una serie de satélites comerciales de alta resolución que captan imágenes de la Tierra, pasando por WorldView-2 y WorldView-3 (Satellite Imaging Corporation, 2017) (Satellite Imaging Corporation, 2018) mismos que gracias a su tecnología de precisión avanzada garantizan que las imágenes satelitales se encuentran alineadas lo más posible con la superficie terrestre, adicional DigitalGlobe permite obtener imágenes claras y con amplia cantidad de información ayudando a mejorar la toma de decisiones (DigitalGlobe, 2021).

En la actualidad existe un extenso grupo de satélites que obtienen imágenes estereoscópicas con diferentes características (Cunha, Lani, Amaral, Rezende, & Ribeiro) (resolución espacial, espectral, radiométrica y temporal) dependiendo del sensor. La

estereoscopía es un requisito para que a partir de las imágenes satelitales se obtenga la elevación del terreno mediante la resolución angular (Chuvienco, 2010) (Pérez & Muñoz, 2006), realizar correcciones en el relieve, entre otras aplicaciones; algunas de las imágenes que son tomadas por satélites son estereoscópicas debido a que el sensor realiza al menos dos barridos simultáneos (vertical y oblicuo) (Quirós & Cuartero, 2005).

Los sistemas de posicionamiento GPS exigen precisión en sus tomas, sin embargo existen diversos factores que causan distorsiones en las señales dando como resultado tomas imprecisas, por cual es indispensable realizar correcciones en las medidas GPS en campo y durante el post – proceso (Zabala, López, & Ortega, 2017), el método NTRIP (*Networked Transport of RTCM vía Internet Protocol*) permite realizar correcciones de las medidas en tiempo real in situ a usuarios estacionarios o móviles a través de internet; involucra protocolos y servidores web para realizar las correcciones necesarias apoyado en la organización de Sistema de Referencia Geocéntrico para las Américas (SIRGAS) y el proyecto SIRGAS en Tiempo Real (SRIGAS-RT) (SIRGAS, 2018) (Zabala, 2018).

A partir de los satélites se obtiene ortoimágenes de manera más rápida y económica, sin embargo para su generación se requiere de empleo de técnicas apoyadas en satélites de posición GNSS que ayuden a la determinación de coordenadas mismas que deben estar ubicadas sobre la superficie topográfica de la Tierra e integradas al sistema de referencia nacional (Ramos, Jimenez, Bernal, & Sánchez, 2019), seguido del proceso de ortorrectificación mismo que corresponde al proceso de corrección geométrica de la imagen removiendo las distorsiones ocasionadas por la orientación del sensor, desplazamiento debido al relieve y errores sistemáticos relacionados con la imagen satelital (Zhao & Moore, 2011).

La forma de obtener cartografía ha ido en constante desarrollo, según las necesidades y la capacidad económica de cada país; el avance de la tecnología ha permitido automatizar varios procesos tales como: disminución de tiempo, recursos y personal. En la actualidad

existen varias técnicas para el procesamiento de grandes volúmenes de información obtenidos de imágenes satelitales, entre las que se destacan la Inteligencia Artificial y el Big Data, mediante la aplicación del Deep Learning (Baluyan, Joshi, Hinai, & Woon, 2013).

La inteligencia artificial nace como disciplina a partir de la concepción de la inteligencia dentro de la rama de la psicología, esta disciplina posee técnicas que se utilizan como herramientas para solucionar problemas (Li & Dong, 2014), hoy en día permite mejorar la calidad de los datos generando modelos de aprendizaje en redes, consiguiendo restaurar ortoimágenes, mejorar la resolución, extraer cartografía a partir de imágenes satelitales, agilizando y facilitando algunos procesos tediosos como el de la digitalización (Basu, y otros, 2015). Varios de los algoritmos que componen los modelos de aprendizaje del Deep Learning permiten resolver una tarea compleja en segundos o minutos, automatizando el uso del tiempo (Bengio, Courville, & Vincent, 2013).

### **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 por lo que se han creado diversos sistemas que permiten lograr estos propósitos (Flores, y otros, 2020); entre estos se pueden destacar el uso de imágenes satelitales e imágenes capturadas por drones, las cuales permiten generar diversos productos como planos y cartas a diferentes escalas, así como ortofotos.

Sin embargo, cabe destacar que una de las ventajas del uso de imágenes satelitales es la rapidez de la adquisición de las mismas ya que en varias ocasiones se puede obtener de manera instantánea a través de internet (Pino & Huayna, 2022). Obtener esta información de un sitio web permite dar a las imágenes satelitales una ventaja sobre los levantamientos topográficos o fotografías aéreas de drones, debido al bajo costo de obtención y la gran extensión que las imágenes satelitales pueden adquirir, otra de las ventajas es la codificación digital de la imagen en las distintas bandas espectrales, ya que se pueden realizar varias

operaciones o algoritmos que destaquen ciertas características de interés; adicional la periodicidad la resolución temporal del satélite permitiendo hacer estudios comparativos a lo largo del tiempo en un mismo lugar de estudio (Pérez M. , 2018).

El Deep Learning permite automatizar y mejorar el proceso de extracción de información cartográfica de grandes extensiones, el avance del tiempo representa un incremento en el espacio urbano por lo que aplicar nuevas herramientas de extracción de información permite actualizar de manera periódica la información esto con el fin de identificar las nuevas zonas en las que existe un nuevo paisaje urbano y poder dar una respuesta rápida a un evento inesperado (Bengio, Courville, & Vincent, 2013). Así mismo el número de personal para la extracción e identificación de nuevas áreas de expansión va a variar debido a que para el Deep Learning es necesario una persona que permita programar y arreglar el modelo según las necesidades del mismo, por lo que permite reducir el costo en operarios.

La presente investigación es de importancia, puesto que se propondrá una alternativa para generar cartografía que pueda ser de utilidad para la planificación del país, debido a que se pretende evaluar si la factibilidad de la generación de cartografía automatizada para escala 1:5000 minimizando tiempos, recursos, mejorando calidad y precisión, en caso de que sea favorable y se den buenos resultados se podría generar un ahorro a la institución que se encargue de implementarlo, adicional se desea evaluar la precisión horizontal en ortoimágenes obtenidas a partir de imágenes satelitales WorldView que poseen diferente nadir, mediante la aplicación de NTRIP que permite obtener el posicionamiento en tiempo real evitando realizar post-procesamiento en los datos obtenidos en campo.

Por lo expuesto, cabe destacar que en la parte académica el presente trabajo de investigación es de gran beneficio, ya que se está incorporando nuevas tecnologías para la generación automática de cartografía y obtención de ortoimágenes, que permitirán optimizar

tiempo desde la toma de puntos en campo hasta la generación de cartografía; logrando la incorporación de nuevas tecnologías relacionadas con la inteligencia artificial.

## **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.
- Ororrectificar 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 geoespaciales 1:5000.

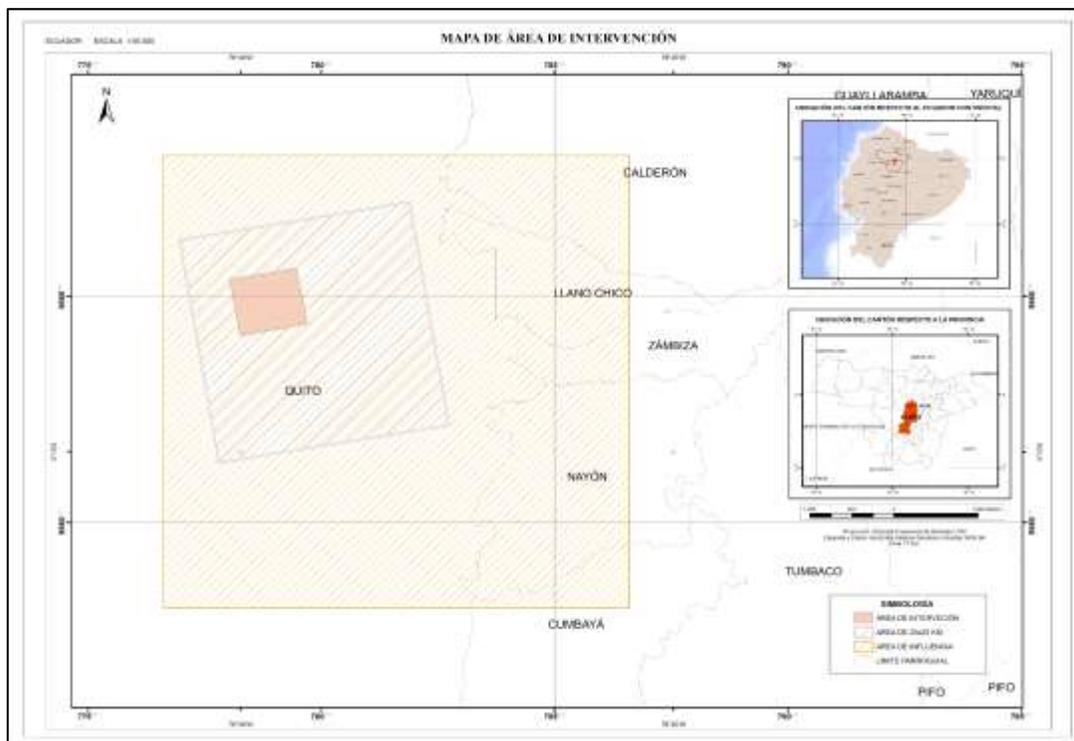
### **Descripción General del Trabajo**

El presente proyecto de investigación propone la generación de ortoimágenes a partir de imágenes satelitales WorldView 2 y 3, con diferente nadir para determinar si los productos obtenidos son aptos para la generación de cartografía a escala 1:5000, los puntos de control tomados para la ortorrectificación se obtuvieron a partir de mediciones con el método NTRIP, se aplicaron dos métodos para la generación de cartografía, digitalización como método tradicional y Deep Learning como nueva tecnología.

El área de intervención para la generación de las ortoimágenes comprende el sector norte del Distrito Metropolitano de Quito, con escenas de 10 x 10 km y de 5 x 5 km (100 km<sup>2</sup> y 25 km<sup>2</sup>), respectivamente; mientras que el área para generar cartografía es de aproximadamente 200 hectáreas dentro de las escenas mencionadas (Ver Figura 1).

**Figura 1.**

*Zona de estudio de la investigación – Cantón Quito*



### Hipótesis

Las precisiones de las ortoimágenes y la cartografía generada a partir de la ortorrectificación de las imágenes satelitales estereoscópicas WorldView y de las técnicas de extracción vectorial, respectivamente, permiten obtener cartografía para escala 1:5000

### Metas

- Dos pares de imágenes satelitales de diferente nadir de 25 km<sup>2</sup>.
- Un par de imágenes satelitales de 100 km<sup>2</sup>.
- Dos elencos de coordenadas con precisiones para generar productos escala 1:5000 utilizables para la ortorrectificación y la evaluación de exactitud posicional.
- Tres ortoimágenes y tres MDS de diferente nadir procesados aplicando la aerotriangulación directa o la aerotriangulación combinada con RPC.

- Un manual del procedimiento de la generación de ortoimágenes.
- Dos productos cartográficos a escala 1:5000 con extensión aproximada de 200 Ha a partir de la técnica de digitalización y Deep Learning.
- Un manual del procedimiento de la generación de cartografía con Deep Learning.
- Dos tablas en el documento de la evaluación de la calidad y exactitud posicional planimétrica y altimétrica de los productos obtenidos a través de la aplicación de las normativas ISO 19157 y NSSDA.

## Capítulo II

### Conceptos y Generalidades

En este capítulo se describe la el enfoque teórico, con la finalidad de comprender el estudio a medida que avance.

#### Visión estereoscópica

Los sistemas de visión estereoscópica funcionan de manera similar a la visión de los animales ya que los ojos proporcionan al cerebro dos vistas de una escena, mismas que son procesadas para proporcionar una representación compleja del entorno, que incluye información de profundidad (Uribe, 2018). La visión estereoscópica permite tener una reconstrucción en vista 3D del entorno, esto se logra mediante el proceso de triangulación de dos imágenes (Gehrig, Schneider, Stalder, & Franke, 2017).

La estereoscopia ha ido en evolución en los últimos años mostrando tendencias globales de optimización para diferentes aplicaciones cartográficas (Gehrig, Schneider, Stalder, & Franke, 2017) tales como fotogrametría aérea, medicina forense, entre otro, en todas estas aplicaciones se utiliza el principio básico de la coincidencia estereoscópica para medir la profundidad real de los objetos (Jain, Singh, Singh, & Malhi, 2017); así también la visión estereoscópica binocular depende de los parámetros geométricos de las cámaras y su calibración ya que esto determina la precisión de la reconstrucción de coordenadas 3D (Wang & Wang, 2019).

#### Imágenes satelitales estereoscópicas

Las imágenes satelitales estereoscópicas presentan esta visión debido a que el satélite realiza un mínimo de dos barridos simultáneos; pueden ser tomadas de manera consecutiva por un mismo satélite a lo largo de una misma órbita en unos segundos (técnica along track o geometría estereoscópica longitudinal) las posiciones de toma son cenital u oblicua, o por el

mismo satélite desde diferentes órbitas en diferentes fechas (técnica across track o geometría estereoscópica lateral) es decir que implica que el sensor tiene la capacidad de giro lateral, dando como resultado una imagen que captura la superficie terrestre desde diferentes ángulos de visión (Fuentes, 2020) (Kassas, y otros, 2021).

Las primeras aplicaciones de las imágenes satelitales estereoscópicas son la generación de modelos digitales de elevación o MDE (Váscones & Pila, 2017) y la generación de ortoimágenes, sin embargo con el avance de la tecnología la resolución espacial de las imágenes ha ido en aumento y estas imágenes se han utilizado para la extracción de edificios para construcción de ciudades en 3D y la generación de modelos digitales de superficie o MDS (Sisti & Soto, 2018).

Mediante el uso de estas imágenes ha sido posible extraer características de la naturaleza que han contribuido al estudio del riesgo volcánico, delimitación de costas, evaluación del riesgo de deslizamientos, actualización de cartografía, movimiento de superficie de los glaciares y montañas, para los casos mencionados se han utilizado puntos de control en el terreno (GCP) (Fuentes, 2020). Existen varios satélites que ofrecen imágenes satelitales estereoscópicas como: SPOT, WorldView, ASTER, entre otros; la mayoría de estos satélites permiten programar el sensor para cambiar el ángulo de visión obteniendo una mejor relación base – altura (Shaker, Yeing, & Easa, 2014).

## **Resoluciones satelitales**

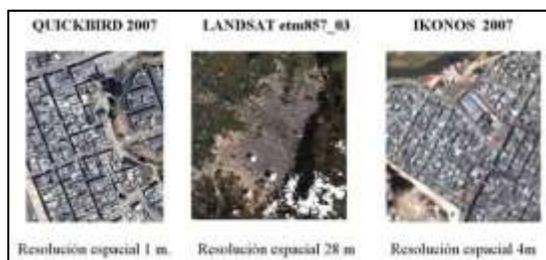
### ***Resolución espacial***

La resolución espacial es el objeto más pequeño que puede identificarse en una imagen y está dado por el tamaño de cada pixel de la imagen proyectada sobre la superficie terrestre. Para determinar la resolución espacial, es necesario identificar el campo de visión instantáneo (IFOV por sus siglas en inglés), que representa el ángulo de visibilidad entre el sensor y el área

de la superficie terrestre que es detectada por el sensor (Paz, Castillo, Cabrera, & Medrano, 2018).

## Figura 2.

### *Resolución espacial de diferentes satélites*



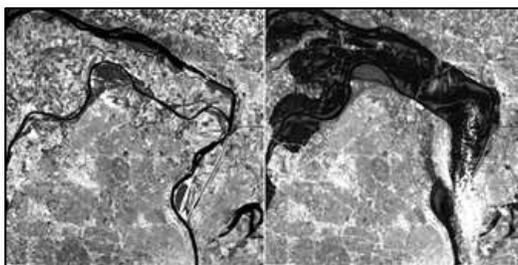
Fuente: (Paz, Castillo, Cabrera, & Medrano, 2018)

### *Resolución temporal*

La resolución temporal es el intervalo mínimo de tiempo en el cual un satélite pasa por la misma zona de estudio en su órbita, también conocido como el periodo de revisita, en otros términos, es la periodicidad con la que se adquieren las imágenes. Se encuentra relacionado con diferentes factores como: punto de vista de las capacidades de los sensores, superposición, y altitud (Paz, Castillo, Cabrera, & Medrano, 2018).

## Figura 3.

### *Resolución temporal*



Fuente: (Paz, Castillo, Cabrera, & Medrano, 2018)

### **Resolución angular**

La resolución angular es la capacidad de un sensor para observar la misma zona desde distintos ángulos. Esta propiedad de determinados sensores es muy interesante desde el punto de vista cartográfico ya que con ella se abren posibilidades de estereoscopia para las imágenes satelitales y por tanto de extracción de información del relieve (Roman-Gonzales & Vargas-Cuentas, 2013) (Guevara, Lara, & Vives, 2018).

### **Figura 4.**

Resolución angular



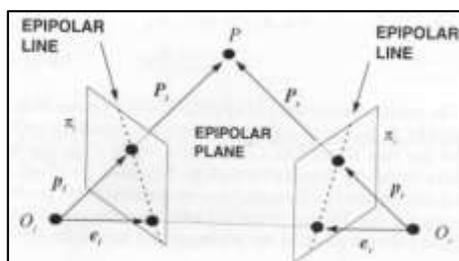
Fuente: (Guevara, Lara, & Vives, 2018)

### **Geometría Epipolar**

La geometría epipolar está fundamentada en los siguientes conceptos y se presenta en la Figura 5:

### **Figura 5.**

*Geometría Epipolar*



Fuente: (Barros & Agudelo, 2015)

### **Plano epipolar**

El plano definido por  $P$ ,  $O_l$  y  $O_r$ , este plano epipolar cruza el plano de la imagen de cada cámara donde forma líneas, las líneas epipolares (Barros & Agudelo, 2015).

### **Línea epipolar**

Se define como línea epipolar a la intersección de un plano epipolar con el plano de la imagen (Barros & Agudelo, 2015).

### **Ortoimagen**

Uno de los productos cartográficos más importantes son las ortoimágenes, ya que son de utilidad como información base para catastro, topografía, fotogrametría, entre otros, los trabajos que emplean ortoimágenes dependen de su calidad métrica, la técnica más utilizada para la generación de ortoimágenes es la rectificación de una foto aérea mediante el uso de un modelo digital del terreno (Segura & Sanchis, 2018).

Una ortoimagen digital es una imagen, en la cual no han sido corregidos los desplazamientos causados por la inclinación de la cámara, sensor y relieve del terreno, está referida a una proyección cartográfica, por lo que posee características geométricas de un mapa (IGM, 2008).

Para la generación de la ortoimagen es necesario empezar con un flujo de trabajo que inicie con la obtención de las fotografías o imágenes satelitales, toma de puntos de control en campo, aerotriangulación, generación de un modelo digital del terreno MDT y ortorrectificación, en caso de requerir cartográfica a partir de la ortoimagen se procede a restituir o digitalizar los elementos cartográficos (IGM, 2008).

### **Ortorrectificación**

El proceso de ortorrectificación elimina la distorsión geométrica en la imagen provocada por la orientación de la cámara o sensor, el desplazamiento provocado por el relieve y el error

del sistema relacionado con la imagen, mediante la ayuda de puntos identificables en la imagen de los cuales se conoce sus coordenadas en el terreno (Rojas, 2018). Realizado el proceso se obtiene una imagen ortorrectificada (ortoimagen) donde se logra identificar objetos o características terrestres con sus verdaderas coordenadas (Recio, 2019).

### **WorldView RPC**

Utilice este modelo para imágenes WorldView o WorldView Legion, incluidos los datos RPC. Este sistema de satélite es un desarrollo de DigitalGlobe. Este modelo requiere el uso de coeficientes polinómicos racionales para describir la relación entre la imagen y la superficie de la Tierra en el momento de la captura de la imagen.

### **Polynomial based Pushbroom**

Los datos pushbroom se recogen a lo largo de una línea de barrido, y cada línea de barrido tiene su propio centro de perspectiva y ángulos de rotación que se modelan mediante funciones polinómicas.

### **Cartografía**

La cartografía es la ciencia encargada del estudio y elaboración de mapas, los cuales son representaciones sobre el plano de toda o una parte de la superficie de la Tierra (Moncada, 2018); ésta ha tenido una gran evolución, pues ha pasado de la cartografía clásica a la cartografía digital o numérica.

#### ***Extracción de cartografía***

Mediante el proceso de extracción cartográfica por medio de imágenes satelitales el técnico evita visitar al terreno, pues el proceso lo realiza mediante digitalización o restitución, el primer proceso conlleva tiempo y es de forma manual, por otra parte está la extracción automática que reduce tanto el tiempo como los equipos usados, y se puede manejar mayor cantidad de información a cartografiar (Campos, 2021), sin embargo también se puede realizar

extracción por medio de modelos matemáticos que dependen de la calidad de las imágenes satelitales (López, Abascal, & Zepeda, 2018). En el caso de estudio se tendrá en cuenta tanto la extracción manual como la extracción automática, que se describen a continuación.

### ***Extracción manual***

La extracción manual muestra información de imágenes satelitales por interpretación humana, por lo general los resultados de esta extracción se acercan a la verdad terrestre debido a que la interpretación se acerca al uso original de la tierra, este tipo de extracción lleva mayor tiempo que la extracción automática (Sefercik, y otros, 2020).

### **Digitalización**

Es una técnica, que a partir del uso de un software especializado y una imagen o ráster se genera información de tipo vectorial de datos geográficos. Los datos vectoriales creados por la digitalización se definen por tener atributos asociados al tamaño y tipo del dato; a la vez posee una geometría específica agrupada a la forma y posición del dato (Olaya, 2014).

### **Topología**

Es el campo de las matemáticas que estudia las relaciones de los elementos en el espacio representado por objetos espaciales (punto, línea, polígono); los datos resultantes de la topología permiten encontrar y corregir errores de la digitalización de la información geográfica (García, 2022). La topología se utiliza para analizar relaciones espaciales, tareas de consultoría y búsqueda y análisis en SIG (Bravo, 2000).

### ***Reglas topológicas***

Dentro de lo que son las relaciones se establecen diferentes tipos de las mismas, conocidas como reglas topológicas. En la plataforma ArcGIS, se implementan dentro de una geodatabase, el usuario elige las reglas que se aplicarán a las entidades. Algunas reglas se aplican a una sola capa, mientras otras pueden combinarse entre dos o más capas. Las reglas

topológicas se aplican en función de su geometría (punto, línea o polígono) (Gers & Cardona).

En la Tabla 1 se muestran las reglas topológicas utilizadas para el programa ArcGIS según la geometría de la capa.

**Tabla 1.**

*Reglas topológicas en ArcGIS*

Tipo de geometría	Reglas
<b>Polígono</b>	<ul style="list-style-type: none"> <li>• Must Be Larger Than Cluster Tolerance (Debe ser mayor que la tolerancia cluster)</li> <li>• Must Not Overlap (No debe superponerse)</li> <li>• Must Not Have Gaps (No debe haber huecos)</li> <li>• Must Not Overlap With (No debe superponerse con)</li> <li>• Must Be Covered By Feature Class Of (Debe estar cubierto por la clase de entidad)</li> <li>• Must Cover Each Other (Deben cubrirse entre sí)</li> <li>• Must Be Covered By (Debe estar cubierto por)</li> <li>• Boundary Must Be Covered By (El límite debe estar cubierto por)</li> <li>• Area Boundary Must Be Covered By Boundary Of (El límite del área debe estar cubierto por el límite de)</li> <li>• Contains Point (Contiene punto)</li> <li>• Contains One Point (Contiene un punto)</li> </ul>
<b>Línea</b>	<ul style="list-style-type: none"> <li>• Must Be Larger Than Cluster Tolerance (Debe ser mayor que la tolerancia cluster)</li> <li>• Must Not Overlap (No debe superponerse)</li> </ul>

- 
- Must Not Intersect (No debe intersectarse)
  - Must Not Intersect With (No debe intersectarse con)
  - Must Not Have Dangles (No deben quedar nodos colgados)
  - Must Not Have Pseudo Nodes (No deben quedar pseudonodos)
  - Must Not Intersect Or Touch Interior (No debe intersectarse o tocar el interior)
  - Must Not Intersect Or Touch Interior With (No debe intersectarse o tocar el interior con)
  - Must Not Overlap With (No debe superponerse con)
  - Must Be Covered By Feature Class Of (Debe estar cubierto por la clase de entidad)
  - Must Be Covered By Boundary Of (Debe estar cubierto por el límite de)
  - Must Be Inside (Debe estar dentro)
  - Endpoint Must Be Covered By (El extremo debe estar cubierto por)
  - Must Not Self-Overlap (No debe superponerse con sí mismo)
  - Must Not Self-Intersect (No debe intersectarse con sí mismo)
  - Must Be Single Part (Debe ser una sola parte)

---

**Punto**

- Must Coincide With (Debe coincidir con)
  - Must Be Disjoint (Debe estar separado)
  - Must Be Covered By Boundary Of (Debe estar cubierto por el límite de)
  - Must Be Properly Inside (Debe estar incluida correctamente)
-

- 
- Must Be Covered By Endpoint Of (Debe estar cubierto por el extremo de)
  - Must Be Covered By Line (El punto debe estar cubierto por la línea)
- 

Fuente: (ESRI, 2016)

### ***Extracción automática***

La extracción automática de imágenes satelitales es una combinación de heterogeneidad de forma y espectral (color), la compacidad y suavidad, cuando se habla de compacidad se hace mención a la cercanía de los píxeles agrupados en un objeto ya que se lo compara en función a una distancia mientras que la suavidad describe la similitud entre imagen y bordes (López, Abascal, & Zepeda, 2018). Mediante la segmentación se logra discriminar las zonas con homogeneidad y heterogeneidad (Barragán, Martínez, & Garzón, 2015).

### **Heterogeneidad espectral**

Se conoce como la desviación estándar de nivel digital (ND) de los píxeles que cubren el objeto extraído, determinada por los objetos que se fusionan de manera adyacente según lo colocado en la escala (Baatz, Benz, Dehghani, & Heynen, 2004) (Quintana, Lillo, Barrera, & J, 2012).

### **Deep Learning**

El Deep Learning trata de redes neuronales artificiales, que se asemejan al cerebro humano, tiene como fin extraer diferentes tipos de cobertura terrestre, carreteras y edificios. El Deep Learning realiza una segmentación semántica, donde cada píxel de una imagen es clasificado en una clase particular, también existe otro tipo de segmentación por instancia, la cual detecta de manera más exacta los objetos donde se observa el borde preciso de cada objeto. Con el uso de este proceso se puede detectar objetos cartográficos en cuestión de

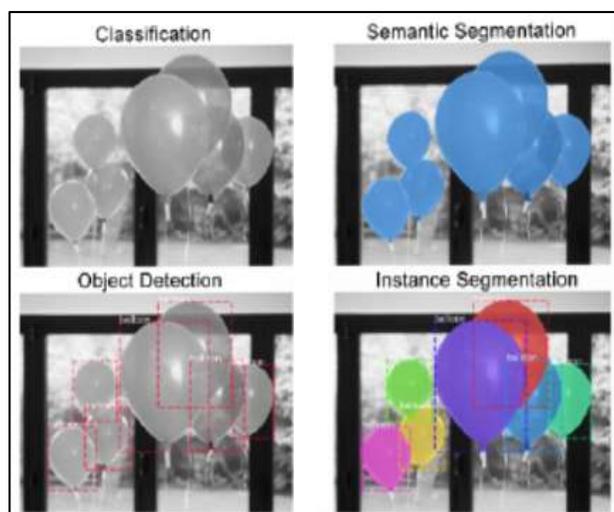
minutos lo cual es una ventaja con respecto a la cartografía tradicional (Kussul, Lavreniuk, Skakun, & Shelestov, 2017).

## Segmentación

La segmentación consiste en agrupar una imagen en varios grupos de píxeles que poseen características similares entre sí, tales como color, textura, patrones, entre otros. (Altamirano, 2021), a partir de la segmentación se puede realizar un modelo de entrenamiento que se adecue a las necesidades del operador, existen varias formas de reconocimiento de objetos en imágenes que parte desde la clasificación en la que se asigna una etiqueta al objeto dentro de la imagen; luego la detección de objetos misma que es la encargada de señalar el objeto de interés en la imagen; segmentación semántica, otorga un único valor al objeto de interés y finalmente la segmentación de instancias que identifica a todos los elementos de diferentes clases como individuales (Catalá, 2021), se muestra un ejemplo en la Figura 6.

### Figura 6.

*Diferencias entre los métodos de segmentación de imágenes*



Fuente: (Catalá, 2021)

### **Modelo U-Net**

Este algoritmo permitirá realizar una clasificación de píxeles a partir de la segmentación de una imagen, en un inicio se lo utilizó para la segmentación de imágenes biomédicas, en la actualidad permite realizar una discriminación a nivel de píxel mostrando las características aprendidas durante el proceso de Deep Learning (ESRI, 2022).

### **Modelo BDCN**

Los seres humanos gracias a su gran percepción visual pueden distinguir entre las características, bordes y límites de los objetos en las imágenes, mientras que un algoritmo se basará en contrastes, colores, entre otros. Bi-Directional Cascade Network for Perceptual Edge Detection (BDCN) permite la detección de bordes de los objetos de las imágenes mediante la asociación de píxeles (ESRI, 2022).

### **Épocas**

Se denomina épocas a las iteraciones en las cuales el modelo va aprendiendo ciertas características, a medida que van en aumento el modelo podrá ir aprendiendo de sus propios errores, por lo cual el modelo llegará a estabilizarse, por lo cual es recomendable colocar un número de épocas grande con la finalidad de identificar en cuál de las épocas el modelo se estabiliza y deja de aprender (Sáenz de la Pascua, 2019)

### **Generalización**

Existen dos procesos de generalización, la primera involucra una generalización conceptual en la cual se presenta un proceso automático en el cual la generalización se llevará a cabo, mientras que la generalización cartográfica permitirá realizar procesos de jerarquía tomando en cuenta la escala, finalidad del mapa, simbología y la resolución, así mismo se evita el uso directo de un software de automatización dando prioridad al criterio del profesional por lo cual se aplican varias operaciones tales como: selección o eliminación de elementos para los

cuales deben aplicarse criterios basados principalmente en la escala; clasificación misma que permitirá representar rasgos representativos de cada clase de elementos; desplazamiento ciertos elementos al encontrarse agrupados pierden jerarquía, por lo cual es indispensable la toma de decisiones y representar el elementos con mayor jerarquía en una posición diferente a la que le corresponde en el terreno (Lagos, 2010).

### Herramientas de generalización

ESRI dispone de varias herramientas que permiten limpiar la información con la finalidad de eliminar datos erróneos, entre las herramientas más importantes se puede destacar:

**Tabla 2.**

*Herramientas de generalización de ESRI*

<b>Herramienta</b>	<b>Descripción</b>
<b>Simplificar polígonos</b>	Permite simplificar los contornos o límites de los polígonos, ya que elimina los vértices extraños.
<b>Suavizar línea</b>	Suaviza los ángulos cerrados con la finalidad de mejorar la calidad cartográfica.
<b>Suavizar polígonos</b>	Suaviza los ángulos cerrados con la finalidad de mejorar la calidad cartográfica.
<b>Simplificar construcciones</b>	Simplifica el límite de las edificaciones, mantiene la forma y tamaño esencial.
<b>Colapsar detalle de carretera</b>	Colapsa aquellos valores pequeños de las carreteras que interrumpen la forma original de la misma.

---

**Eliminar**

Permite eliminar polígonos menores, mayores o iguales a un área determinada.

---

Fuente: (ESRI, 2019)

**Cartografía planimétrica**

Los elementos planimétricos a ser representados se especifican en el Catálogo Objetos 1:5000 del Instituto Geográfico Militar (IGM), los cuales deberán contener todos los detalles identificables, en su exacta posición y verdadera forma, con dimensión mínima a 2,5 m en el plano; si se tuviese otros elementos de interés de menos dimensión a la antes mencionada se representarán de manera general por medio de símbolos (IGM, 2016).

En cuanto a la cartografía planimétrica se deben representar todas las áreas de interés, como son: zonas edificadas, parques, plazas, vías de comunicación, líneas de conducción, entre otras que estén contempladas en el catálogo (IGM, 2016).

**Satélite WorldView-2**

El satélite WorldView-2 es uno de los satélites ópticos de muy alta resolución perteneciente a DigitalGlobe, fue lanzado el 8 de octubre de 2009, se encuentra a 770 kilómetros de altitud, ofrece una resolución multiespectral de 1.85 metros, la información que proporciona es de tipo monoscópica y estereoscópica por lo cual es utilizado para la generación de cartografía y detección de cambios, tiene un tiempo de revisita menor a 4 días (DigitalGlobe, 2014).

**Satélite WorldView-3**

El satélite WorldView-3 es el primer satélite comercial de alta resolución, hiperspectral, se encuentra a 617 kilómetros de altitud, ofrece una resolución pancromática de 31 centímetros, resolución multiespectral de 1.24 metros, resolución infrarroja de onda corta de 3.7

metros y una resolución CAVIS (Clouds, Aerosols, Vapours, Ice and Snow) de 30 metros (MAXAR, 2020).

Tiene un tiempo de revisita menor a un día, la información recogida es de tipo monoscópica y estereoscópica, su capacidad global es de 680.000 km<sup>2</sup> por día; los productos obtenidos del satélite WorldView-3 son de utilidad para generar cartografía, clasificaciones del terreno, análisis de suelos, realizar detección de cambios, monitorización medioambiental, entre otros, posee 1 banda pancromática, 8 bandas multispectrales, 8 bandas SWIR y 12 bandas CAVIS (MAXAR, 2020).

### **Image Metadata Data (IMD)**

Es una extensión que está asociada a datos SIG, contiene los metadatos del ráster tales como el ID de catálogo, descripción de la imagen, el nivel, sistema de referencia, entre otros; por lo cual el IMD se utilizará para georreferenciar las imágenes en su verdadera posición en el terreno, adicional contiene información acerca de los archivos con extensión, .TIFF, .GeoTiff, entre otros. Cabe mencionar que en el caso de un ortomosaico si la imagen de entrada no se utiliza como parte del producto final esta no se encontrará en el archivo IMD, las imágenes de entrada utilizadas aparecerán en orden según la fecha de adquisición desde la más antigua a la más nueva (MAXAR).

### **Tile Map File**

Las imágenes grandes se dividen en varias subimágenes y se distribuyen como un grupo de archivos de subimágenes denominados mosaicos, mismos que no tienen un tamaño uniforme, permiten visualizar varias subimágenes del mosaico base (MAXAR).

### **Estaciones de monitoreo**

El IGM se encuentra a cargo de la Red GNSS de Monitoreo Continuo del Ecuador REGME, que son las estaciones de monitoreo continuo distribuidas a lo largo del territorio

nacional, existe un radio de cobertura de 50 kilómetros por cada estación, esto permite optimizar los recursos tanto económicos como logísticos y humanos (Instituto Geográfico Militar, s.f.).

Los datos que proporcionen serán utilizados para realizar trabajos como: Catastro a gran escala, ordenamiento territorial, levantamientos topográficos, gestión de riesgos, posicionamiento GPS y determinación de coordenadas de alta precisión, remediación ambiental, entre otros, la REGME es el conjunto de estaciones GNSS (GPS y GLONASS) de monitoreo continuo, enlazadas con la RENAGE y la Red Continental SIRGAS (Instituto Geográfico Militar, s.f.).

### **Métodos de posicionamiento**

Son aquellos métodos o técnicas que se utilizan para determinar la posición de objetos estáticos o en movimiento, se clasifican según varios factores que pueden ser el sistema de referencia, método de observación, o el modo de procesamiento.

#### ***Fast Static***

Corresponde a un método de observación, es considerado una variante del método estático clásico el cual consiste en estacionar dos receptores o más en aquellos puntos en los cuales se desea conocer sus coordenadas, siendo necesario tener al menos una coordenada conocida, los receptores permanecen de forma estática durante la observación; mientras que el método estático rápido utiliza receptores de bifrecuencia equipados con algoritmos que brindan una solución en un poco tiempo de observación (Cisneros, García, Montoya, & Sinde, 2019).

Se lo realiza de la misma manera que el método estático clásico solo que estacionando el equipo dos veces en un punto, con una diferencia en el estacionamiento de una hora, esto para que la geometría de la constelación varíe, dando como resultado una mejor solución (Cisneros, García, Montoya, & Sinde, 2019).

### **Protocolo NTRIP**

El server NTRIP permite que los usuarios puedan posicionarse en tiempo real de manera precisa, siendo una de las ventajas el obtener coordenadas corregidas sin necesidad de realizar cálculos ni post procesamiento (Camisay, Mackern, & Calori, 2013), ya que estas coordenadas son calculadas en una estación base y entregadas a los usuarios por medio del internet a un servidor denominado Caster NTRIP (IGN, 2019).

Los servidores NTRIP, transfieren datos RTCM por medio de estaciones GPS/GNSS, que se envían al Caster NTRIP a través de una conexión IP.

- Caster NTRIP, es un servidor de internet que transfiere las correcciones calculadas a los usuarios.
- Clientes NTRIP, es el receptor de las correcciones calculadas, que utiliza para obtener su posición en tiempo real de manera precisa (Silva, Rodino, & Peláez, 2013).

### **Puntos de control**

Los puntos de control del terreno o Ground control points (GCP), son aquellos puntos cuya ubicación es conocida y son de utilidad para georreferenciar la nube de puntos obtenida mediante trabajo de campo, así mismo para realizar el ajuste de los bloques fotogramétricos y para generar el Modelo Digital de Elevación y la ortofoto, la necesidad de tener GCPS de calidad se termina por los requisitos de precisión de los productos cartográficos (Kumar & Da Silva, 2018).

### **Alturas elipsoidales**

Son también conocidas como alturas geodésicas, puede ser determinada directamente por sistemas geodésicos espaciales como el GPS (Cappellotto, Acosta, Pérez, Orgeira, & Gómez, 2020), la relación existente entre la altura elipsoidal  $h$ , la altura ortométrica  $H$  y la ondulación geoidal  $N$  se da de la siguiente manera en la ecuación (Palacios & Arellano, 2022).

### **Rational Polynomial Coefficients (RPC)**

Los coeficientes polinomiales racionales (RPC) describen un modelo de geometría de imágenes que transforma las coordenadas de píxeles de la imagen en coordenadas terreno en base a la geometría del sensor y su posición (teniendo en cuenta los errores de desplazamiento del terreno) esta información será de utilidad para rectificar la imagen. Utilizan datos de altura que se extraen del modelo de elevaciones utilizado por el proveedor, la extensión con la que se puede identificarlos es .rpb y se encuentra en las imágenes Ortho Ready, System-Ready y View-Ready (Díaz, 2018).

### **Modelo Digital de Superficie (MDS)**

El Modelo Digital de Superficie (MDS) puede definirse como cualquier representación numérica de una determinada superficie de terreno físico (1999); es así que puede expresar varios tipos de atributos como: temperatura, presión, y pendiente, y por supuesto, altitud. Cuando un MDS representa altitud se puede denominar Modelo de Elevación Digital (MDE o DEM) (Neuman, y otros, 2018).

### **Nadir**

Es la proyección vertical del centro de la cámara sobre el terreno en el momento de la exposición. Cuando la fotografía es absolutamente vertical, el nadir coincide con el Punto Central, es decir, con la proyección del eje óptico (Posada, 2013); entonces el punto Nadir es la intersección de la vertical que pasa por el centro de proyección con el plano del negativo (Neira, 2005).

### **Exactitud posicional**

Según el IGM (2006) se define a la exactitud posicional como la exactitud de la posición de los objetos (IGM, 2016). También se refiere a la proximidad entre los valores de los objetos

que pertenecen al producto de datos con respecto a los valores verdaderos (Ariza, García, Rodríguez, & Robledo, 2019).

### **Precisión**

La precisión se define como la proximidad entre mediciones repetitivas de un mismo objeto o de objetos similares, está asociado a mediciones reiteradas aplicando los mismos parámetros (Ruiz, García, & Mesa, 2010).

### **Control de calidad**

#### ***Norma ISO 19157:2013***

Establece los principios para describir la calidad de los datos geográficos, sus componentes y estructura de los registros de mediciones, así como también los procedimientos generales para calificar e informar la calidad de los datos geográficos (Guinea, 2014). Esta trata sobre la calidad de datos geográficos, mediante la cual se evalúa temas como exactitud posicional, exactitud de los atributos, consistencia lógica y coherencia topológica (IGM, 2016).

#### ***Norma NSSDA***

Conocida como Estándar Nacional de Precisión de Datos Espaciales, es un método que verifica la exactitud de los datos geográficos, tanto en componente horizontal como vertical; toma en cuenta el error medio cuadrático (RMSE) con un determinado nivel de confianza (FGDC, 1998). Para la valoración del componente X e Y se aplican las siguientes ecuaciones (1) y (2):

$$RMSE_x = \sqrt{\frac{\sum (x_{carto_i} - x_{obs_i})^2}{n}} \quad (1)$$

$$RMSE_y = \sqrt{\frac{\sum (y_{carto_i} - y_{obs_i})^2}{n}} \quad (2)$$

Donde:

$x_{carto_i}$  y  $y_{carto_i}$ , coordenadas obtenidas en la cartografía.

$x_{obs_i}$  y  $y_{obs_i}$ , coordenadas de chequeo observadas en campo.

$n$ , número de puntos a ser evaluados.

$i$ , número entero entre 1 y  $n$ .

Para valorar la componente posicional para XY se la realiza a través de la siguiente ecuación (3):

$$RMSE_r = \sqrt{\frac{\sum(x_{carto_i} - x_{obs_i})^2 + \sum(y_{carto_i} - y_{obs_i})^2}{n}} \quad (3)$$

Para el 95% de nivel de confianza ASPRS (2013), indica que tiene dos casos los cuales son:

Caso 1: cuando  $RMSE_x = RMSE_y$  la exactitud posicional se calcula con la ecuación (4):

$$Exactitud\ r = 1.7308(RMSE_r) \quad (4)$$

Caso 2: si  $RMSE_x \neq RMSE_y$  se aplica la ecuación (5):

$$Exactitud\ r = 2.4477 \times 0.5 \times (RMSE_x + RMSE_y) \quad (5)$$

Para la componente Z se emplea la ecuación (6):

$$RMSE_z = \sqrt{\frac{\sum(z_{carto_i} - z_{obs_i})^2}{n}} \quad (6)$$

La exactitud para un nivel de confianza del 95% se calcula con la ecuación (7):

$$Exactitud_v = 1,96 * RMSE_z \quad (7)$$

### **Tamaño de la muestra en exactitud posicional**

El tamaño de la muestra para la exactitud posicional según la norma “Positional Accuracy Standards for Digital Geospatial Data” (ASPRS), indica que el número de puntos de varía según el área a cubrir, a continuación se detalla en la Tabla 3.

**Tabla 3.**

*Tamaño de la muestra de puntos en función al área de estudio*

Área (km <sup>2</sup> )	Número de puntos de exactitud posicional
500	20
501-750	25
751-1000	30
1001-1250	35
1251-1500	40
1501-1750	45
1751-2000	50
2001-2250	55
2251-2500	60

Fuente: (ASPRS, 2013)

### **Exactitud posicional de acuerdo al Instituto Geográfico Militar (IGM)**

El IGM se base en la norma NSSDA para estimar la exactitud posicional. Para el cálculo de la exactitud posicional planimétrica a un 90% de confianza, se deberán tomar en cuenta 2 casos (IGM, 2018).

Caso 1: cuando  $RMSE_x = RMSE_y$ , la exactitud posicional se calculará de la siguiente manera:

$$Exactitud\ r = 1.5175 * (RMSE_r) \quad (8)$$

Caso 2: cuando  $RMSE_x \neq RMSE_y$ , la exactitud posicional se calculará de la siguiente manera:

$$Exactitud\ r = 2.1460 * 0.5 * (RMSE_x + RMSE_y) \quad (9)$$

### **Precisiones planimétrica y altimétrica según el Instituto Geográfico Militar**

La precisión planimétrica se cumplirá al 90% por la ecuación (10), en cuanto a la altimetría el 90% se referirá a la ecuación (11) (IGM, 2016).

Para la elaboración de planimetría se debe tener en cuenta la siguiente ecuación:

$$P_H = 0.3\ mm * factor\ de\ escala \quad (10)$$

$$P_V = \frac{1}{4} * Intervalo\ de\ curva\ de\ nivel \quad (11)$$

### **Precisión de los puntos de control (GCP) según el Instituto Geográfico Militar**

Los GCP deben ser de mayor precisión que la cartografía generada, viene dada por la siguiente ecuación (IGM, 2006):

$$PH_{GCP} = 0.01\ cm * M \quad (12)$$

Donde:

$PH_{GCP}$ : Precisión de los puntos de control (GCP)

M: Módulo de la escala

Sin embargo, en la vida práctica se utiliza la siguiente fórmula:

$$P_{GCP} = \frac{PH}{4} \quad (13)$$

Donde:

PH: Precisión horizontal

## **Estadísticos**

### ***Media***

Se trata del valor que se obtiene al sumar todas las observaciones, dividido para el total de las observaciones de la muestra, es decir, el promedio de las observaciones (Lind, Marchal, & Wathen, 2012).

### ***Desviación estándar***

Es una medida de tendencia central, se obtiene mediante la raíz cuadrada de la media aritmética de las desviaciones de la media al cuadrado (Lind, Marchal, & Wathen, 2012).

### ***Nivel de confianza***

Es la probabilidad máxima de que los puntos de un conjunto de datos se encuentren dentro del intervalo estimado, se representa como porcentaje (Lind, Marchal, & Wathen, 2012).

### ***Error medio cuadrático (RMS)***

Es la raíz cuadrada del promedio de las diferencias entre los valores de coordenadas y los valores de coordenadas de una fuente con mayor precisión de los mismos puntos (IGM, 2020).

## **Capítulo III**

### **Metodología**

En este capítulo se detalla la metodología utilizada para elaborar el proyecto de investigación, empezando por la recopilación de la información, toma de puntos de apoyo, ortorrectificación, digitalización, Deep Learning y control de calidad de datos.

Para ello, se aplicaron métodos inductivos: recopilación de información, digitalización; métodos inductivos y experimentales: toma de puntos de apoyo, ortorrectificación; métodos deductivos y experimentales: Deep Learning y métodos comparativos: control de calidad de datos.

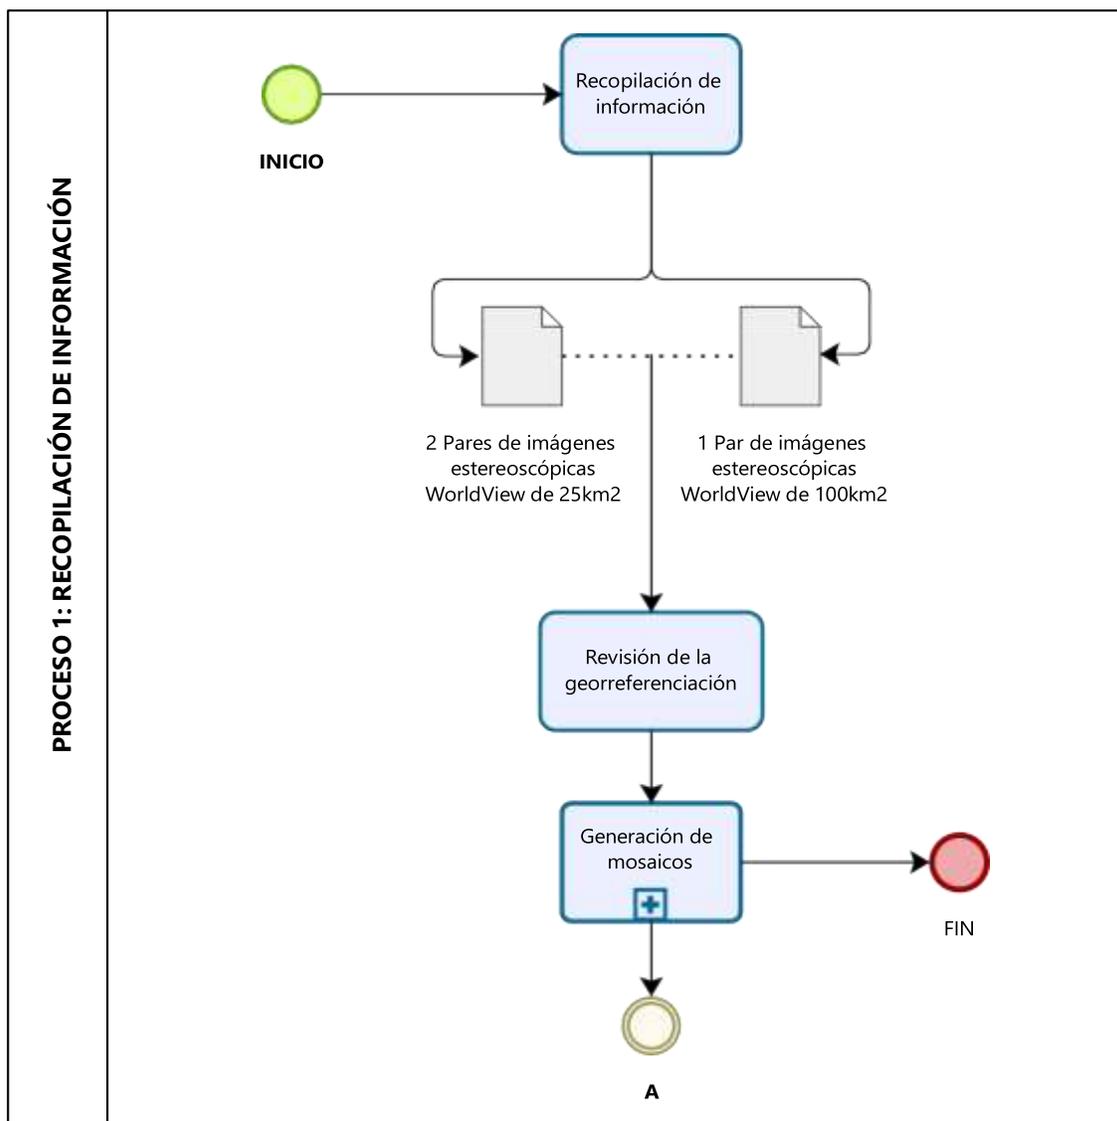
### **Generalidades**

La elaboración del proyecto de investigación se desarrolla empezando por la obtención de información, generación de ortoimágenes, producción de cartografía por las técnicas de digitalización y Deep Learning; así como, la topología y catalogación, evaluando su calidad a través de la norma ISO 19157 y finalmente, evaluar la exactitud posicional mediante la norma NSSDA. En la Figura 7, se observa el flujograma de procesos a seguir en el proyecto de investigación.

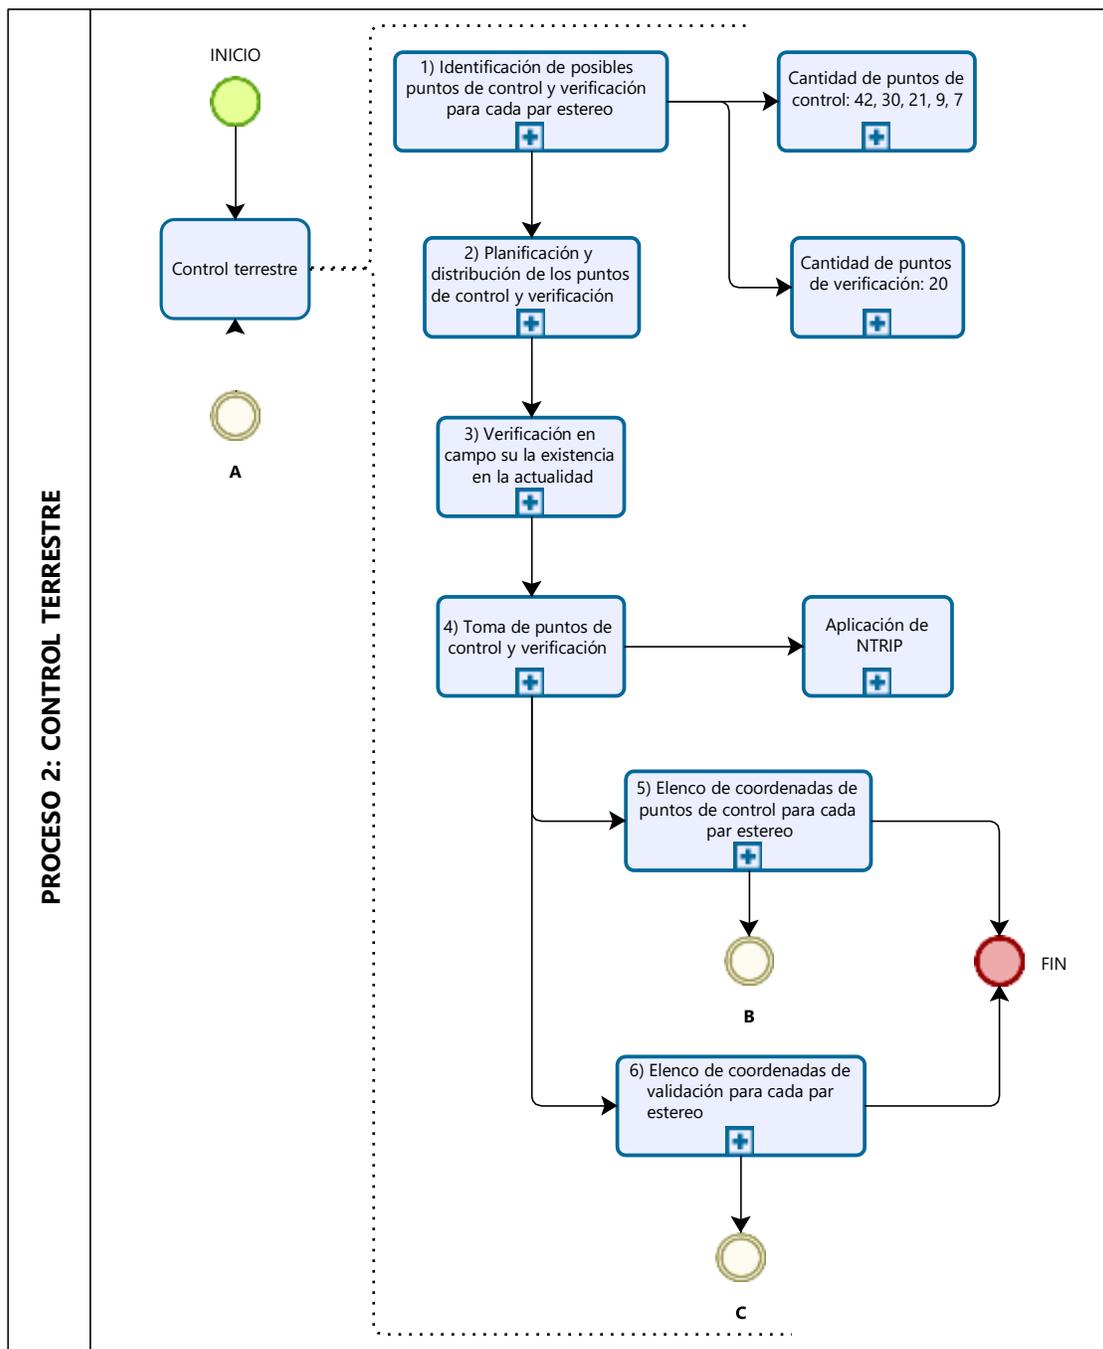
Figura 7.

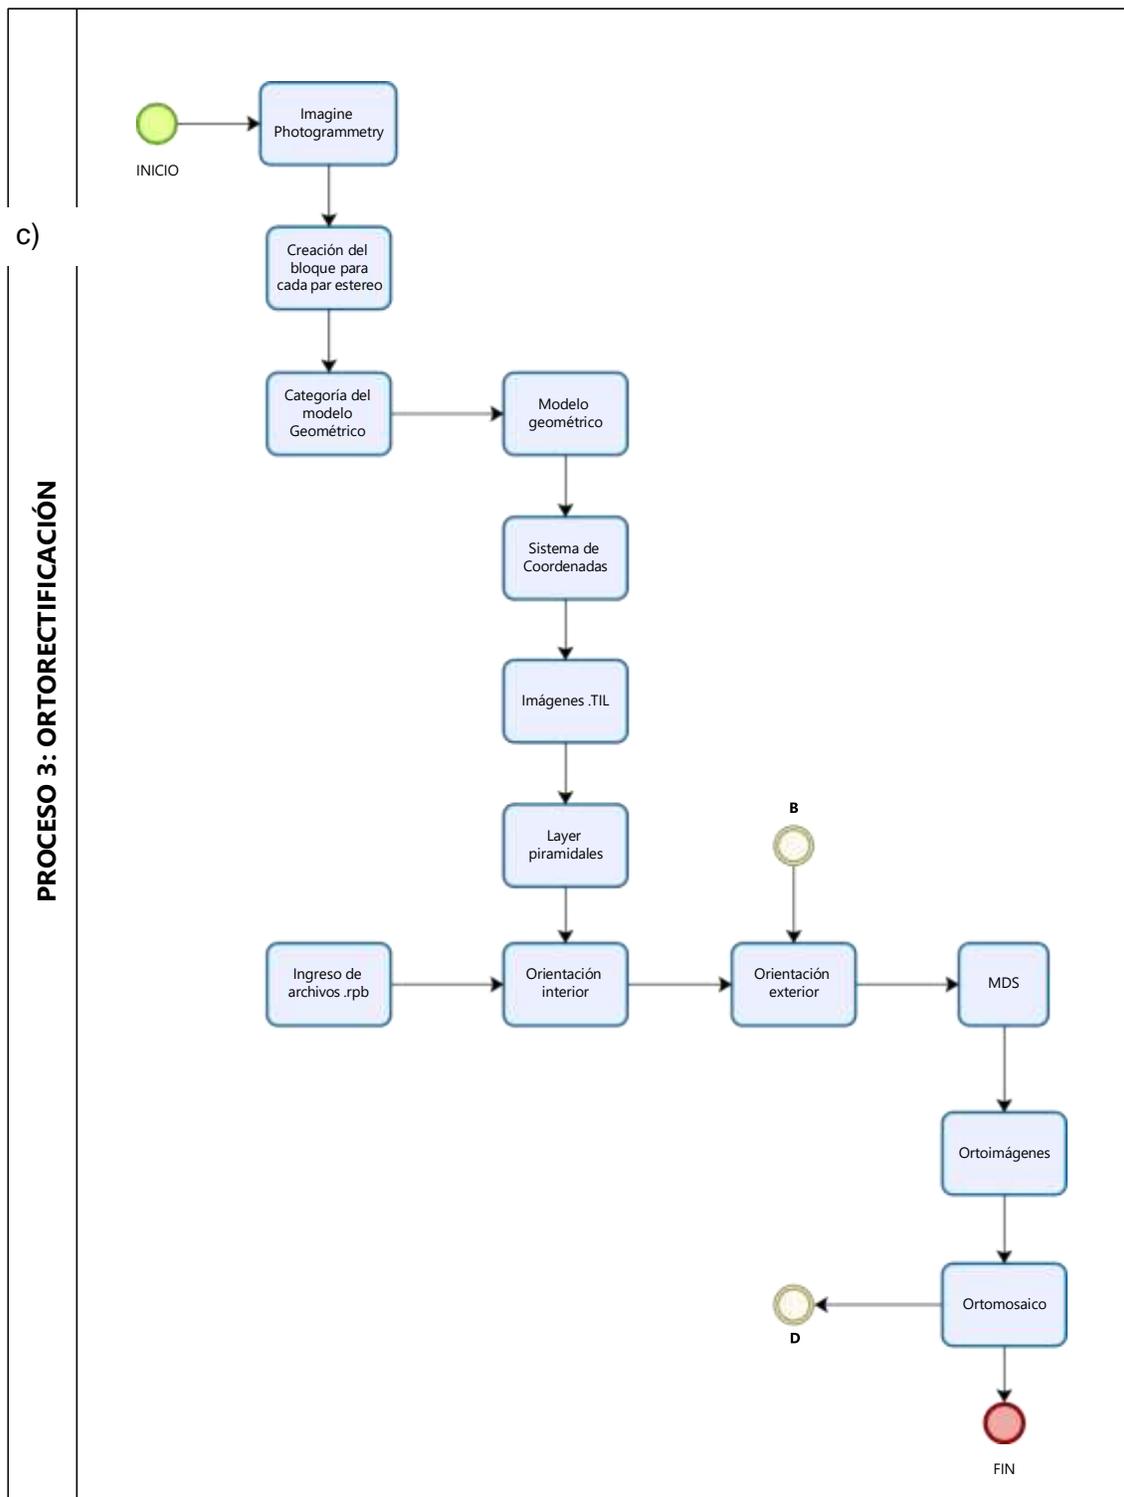
Flujograma general de la metodología seguida

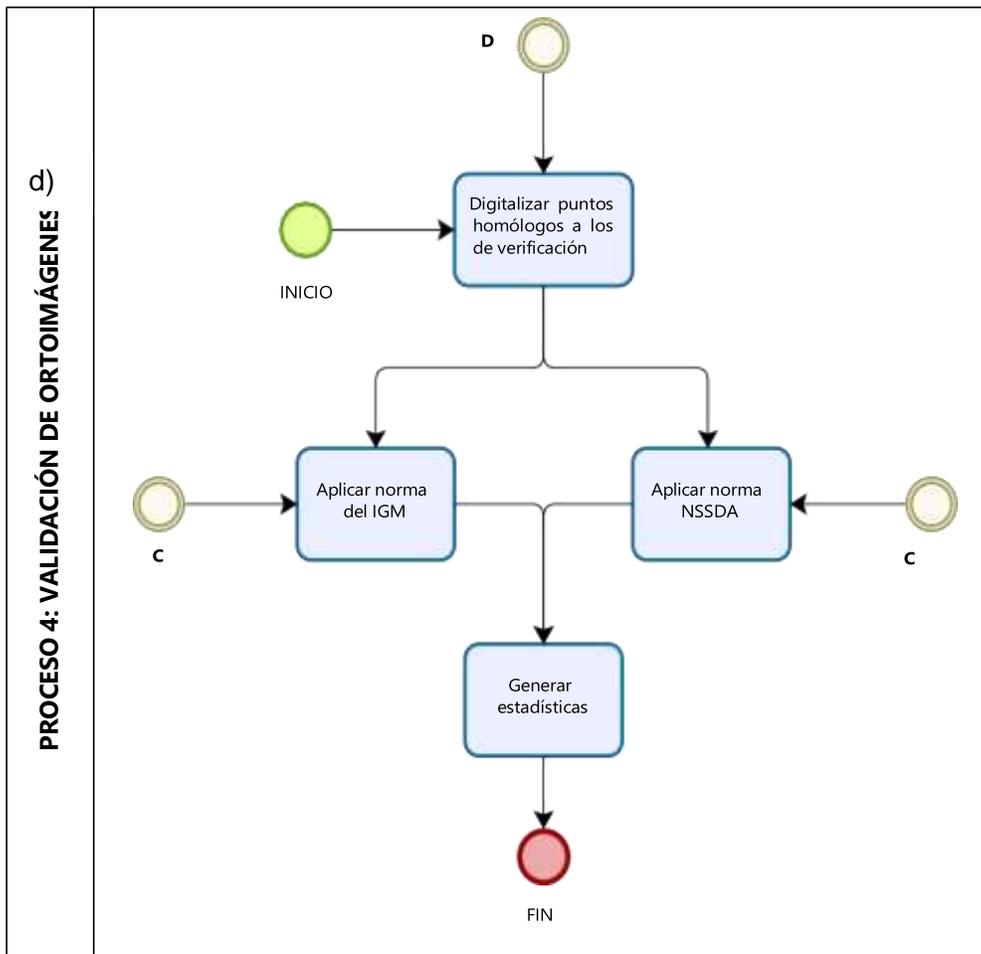
a)



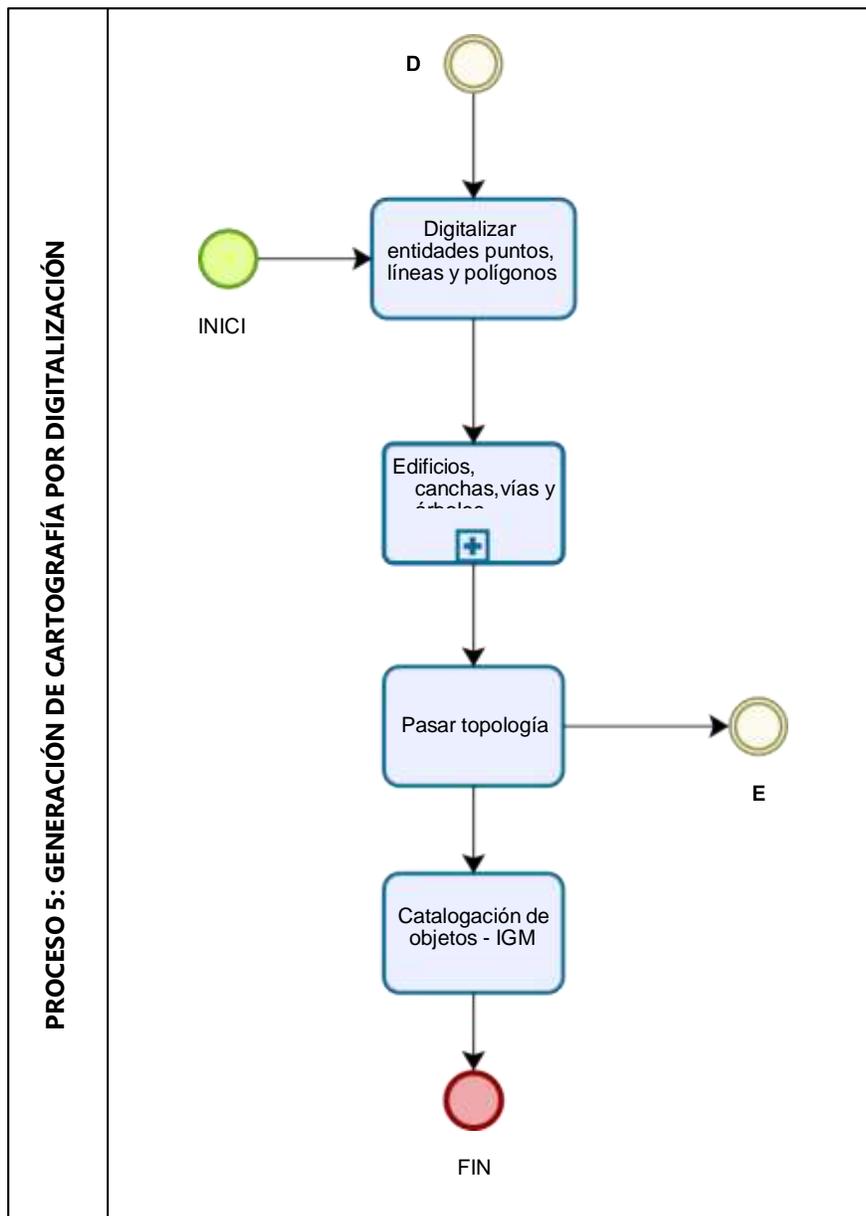
b)



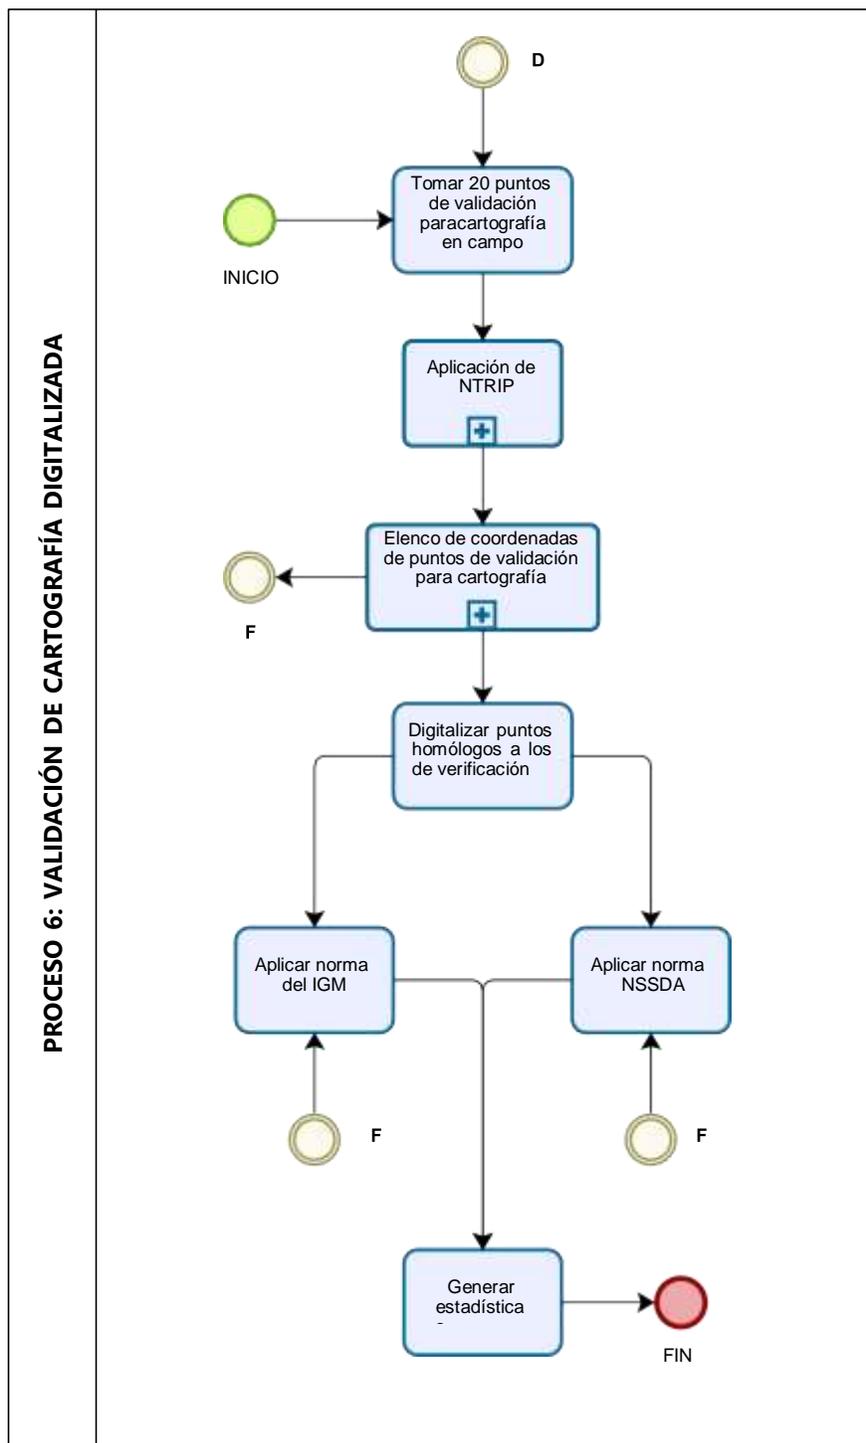




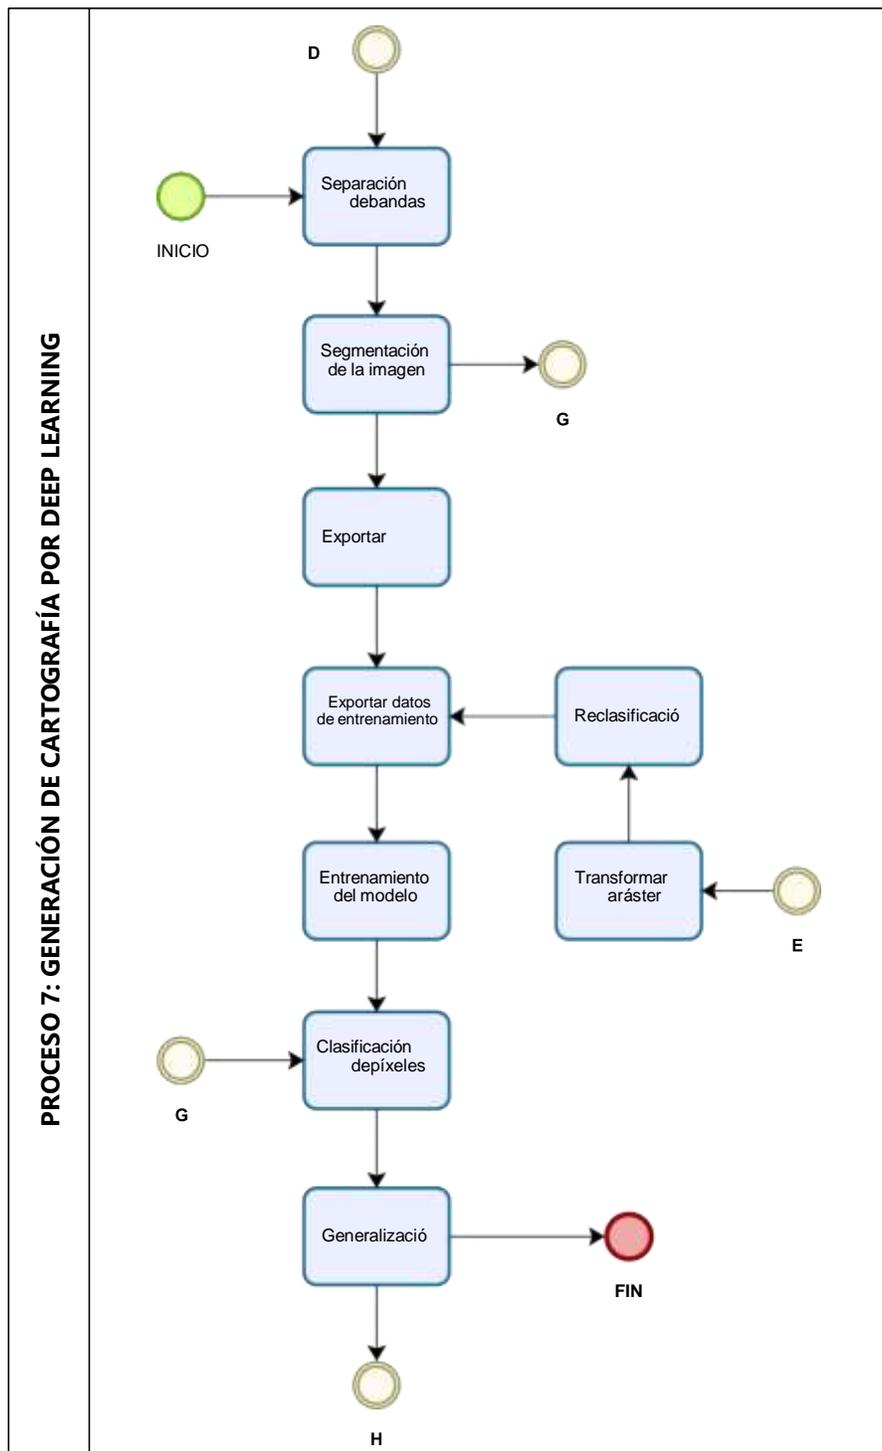
e)



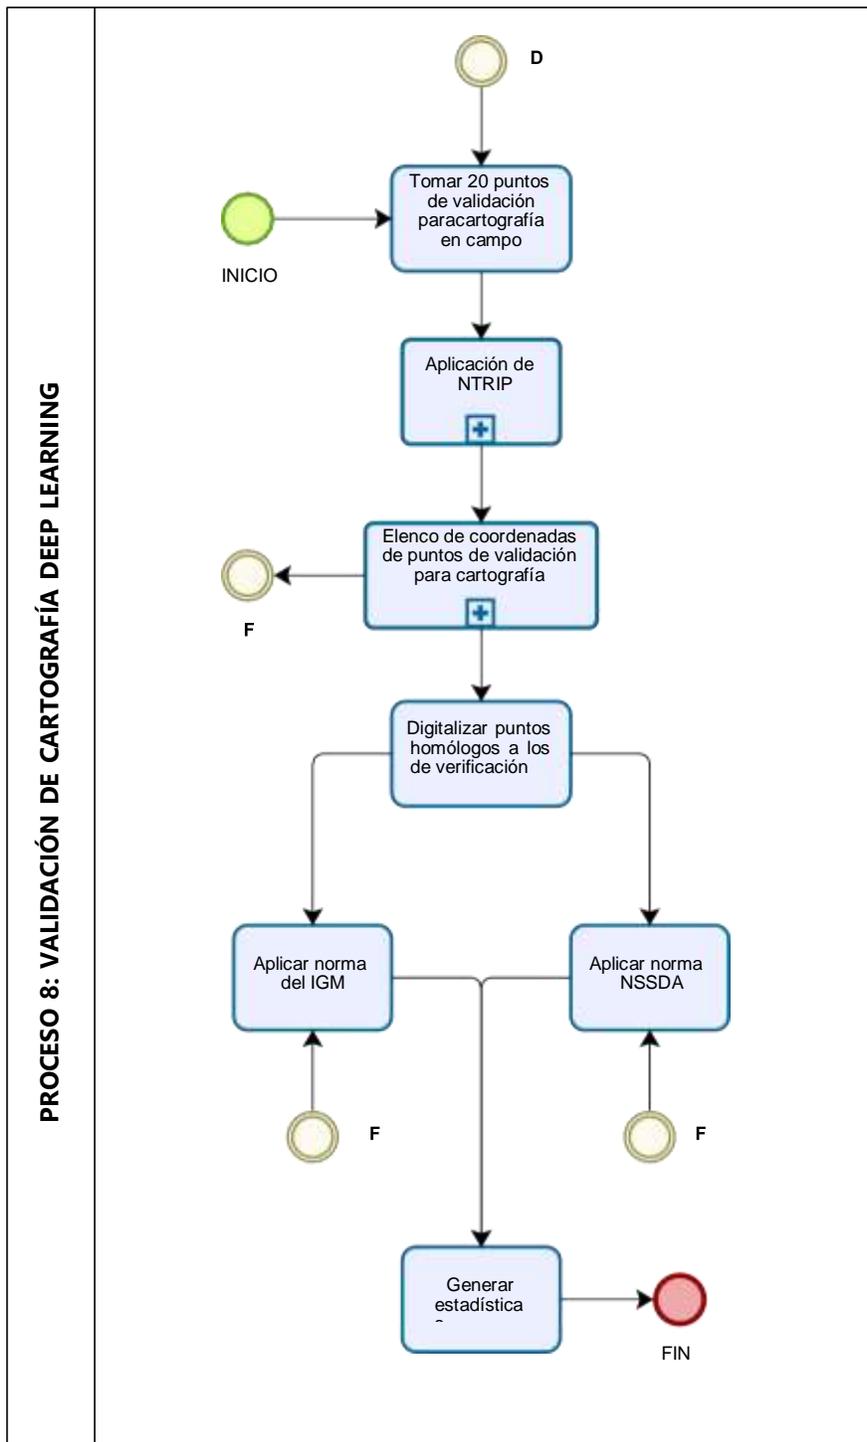
f)



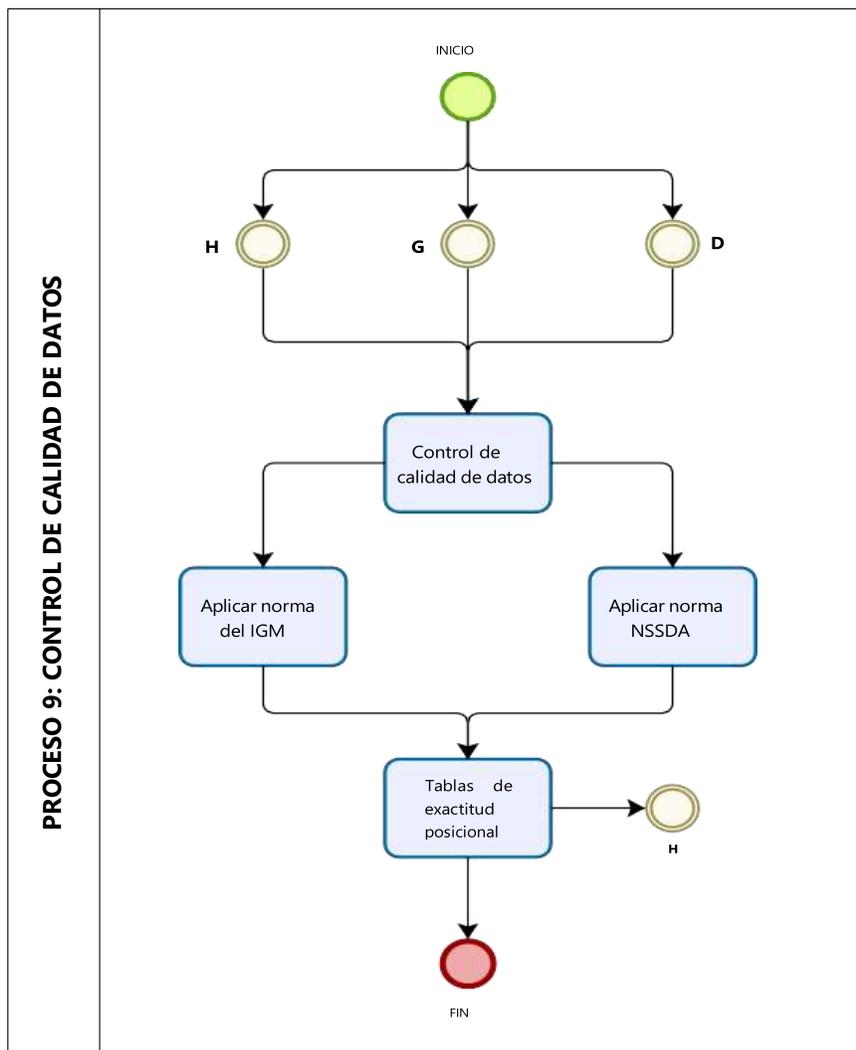
g)



h)



i)



*Nota.* Flujo general dividido en procesos: a) Recopilación de información, b) Control terrestre, c) Ortorrectificación, d) Validación de ortoimágenes, e) Generación de cartografía por digitalización, f) Validación de cartografía digitalizada, g) Generación de cartografía por Deep Learning, h) Validación de cartografía por Deep Learning, i) Control de calidad de datos

### Obtención de información

Con petición a la Empresa GEOINT Ltda, se adquirieron imágenes satelitales estereoscópicas de los sensores WorldView-2 y WorldView-3 de los años 2014, 2016 y 2018

respectivamente, las especificaciones y características se muestran a continuación en la Tabla 4.

**Tabla 4.**

*Especificaciones de las imágenes satelitales estereoscópicas*

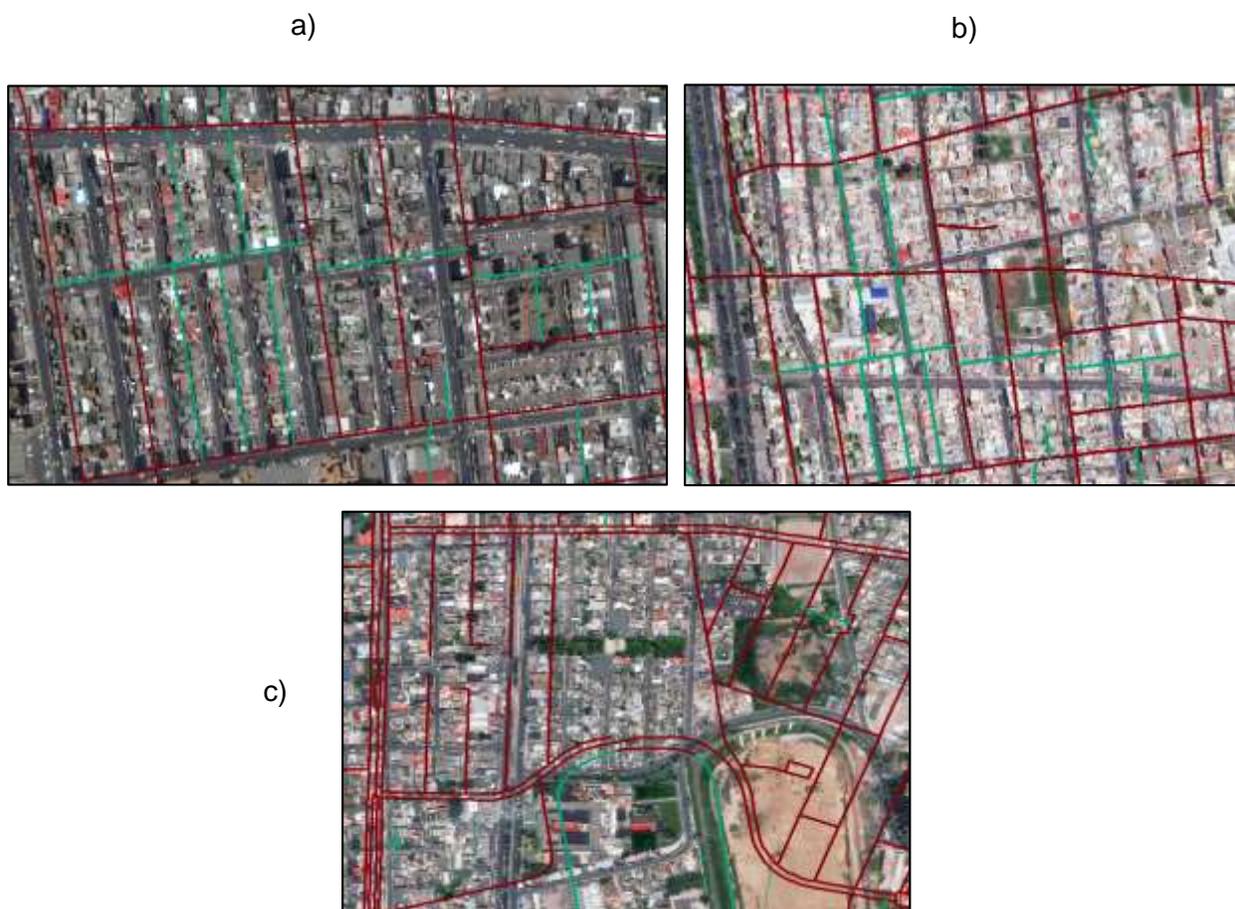
<b>Características</b>	<b>Años</b>		
	2014	2016	2018
<b>Tipo de sensor</b>	WorldView-3	WorldView-2	WorldView-3
<b>Identificación de imágenes</b>	104001000115E200, 1040010001C94200	10300100514BE800, 103001004FC40F00	104001003D98C200, 104001003D984600
<b>Cobertura</b>	100 km <sup>2</sup>	25 km <sup>2</sup>	25 km <sup>2</sup>
<b>Nadir</b>	13.1°	26.0°	27.7°
<b>Porcentaje de nubes</b>	1.0%	2.8%	5.7%
<b>Número de Bandas</b>	4	4	4
<b>Resolución Espacial</b>	0.40 m	0.50 m	0.40 m
<b>Resolución Radiométrica</b>	8 bits	8 bits	8 bits
<b>Traslapo</b>	99.8%	96.6%	99.18%
<b>Sistema de Referencia</b>	WGS84		
<b>Proyección</b>	UTM, 17S		

### **Control Terrestre**

Previo a la planeación de la ubicación de puntos de apoyo y puntos de validación de exactitud posicional es necesario realizar la revisión de la georreferenciación de las imágenes satelitales adquiridas, para ello se superpuso la cartografía a escala 1:5000 perteneciente al IGM sobre las imágenes satelitales, como se ilustra en la Figura 8, se observa que la información no es coincidente, adicional a esto, se tomaron algunas muestras de medidas que indican el desplazamiento existente, como se muestra en la Tabla 5.

### **Figura 8.**

Revisión de georreferenciación



*Nota.* Imágenes de los años: a) 2014, b) 2016, c) 2018

**Tabla 5.***Muestras de medidas*

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

Antes de realizar el control, se debe tener conocimiento de la zona de estudio, verificando la existencia del punto base (estaciones de monitoreo continuo), tiempo de rastreo, distribución de puntos GPS que servirán de apoyo en el proceso de orientación exterior y, la distribución de otros puntos independientes que servirán para la validación de la exactitud posicional, tanto para las ortoimágenes como para la cartografía. Se planificaron 42 puntos en el área de estudio, marcando los puntos fotoidentificables en la imagen, se debe verificar que estos puntos no hayan cambiado con el paso del tiempo y se encuentren hasta la actualidad, ya que las imágenes adquiridas son de los años 2014, 2016 y 2018, también, es importante que sea seguro el acceso al sitio de toma de puntos.

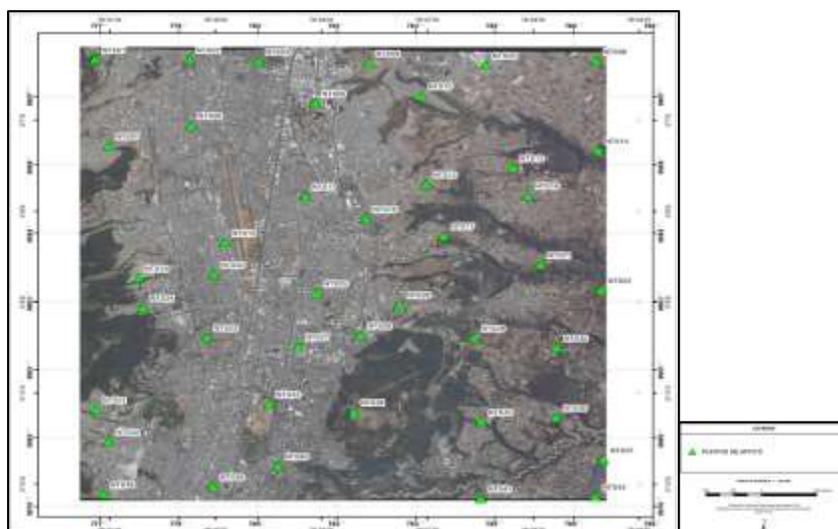
### ***Planeación de la ubicación de puntos de control***

En la planificación del número ideal de GCP, se siguieron las recomendaciones de una investigación previa, del año 2012, titulada: “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” cuyo autor es Kirby E.; en la investigación, se estableció probar con 7 puntos, 9 puntos, 21 puntos, 30 puntos para pendiente baja y 42 para pendiente media.

La distribución de los puntos de apoyo (GCP) y los puntos de validación de exactitud posicional fue casi simétrica (aleatoria), colocando los GCP a ras de piso, en ángulos rectos, y que existan puntos en zonas planas y altas. Una vez analizada la distribución de puntos en base a la topografía del terreno, se colocaron más puntos de apoyo en los extremos de las imágenes satelitales, ya que se observa un mayor cambio en la topografía del área de interés, como se muestra en las Figuras 9, 10 y 11. En cuanto a los puntos de validación de exactitud posicional, se tomaron los mismos criterios de los puntos de apoyo, como se observa en las Figuras 12, 13, 14 y 15.

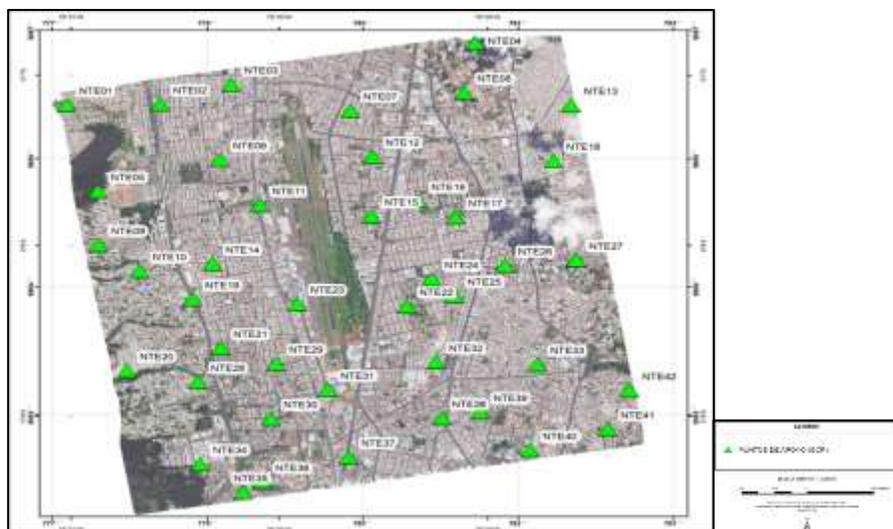
### **Figura 9.**

*Propuesta de distribución de puntos de apoyo (GCP) por estéreo del año 2014*

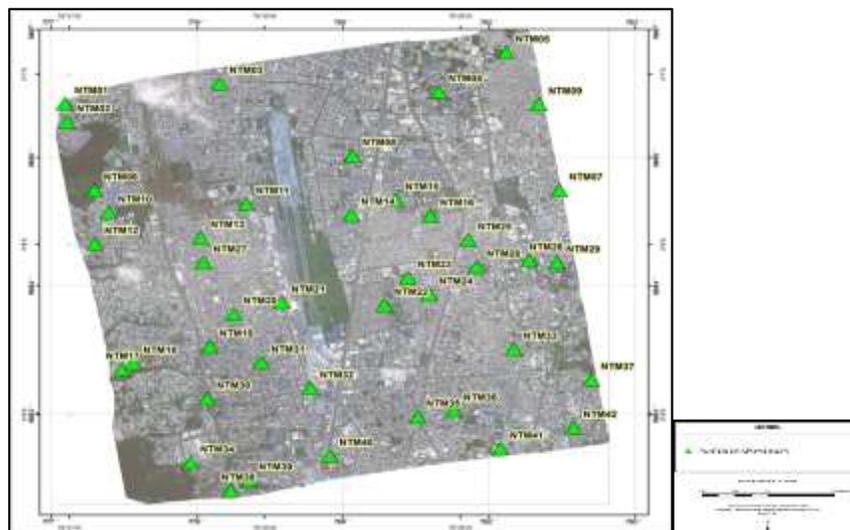


**Figura 10.**

*Propuesta de distribución de puntos de apoyo (GCP) por estéreo del año 2016*

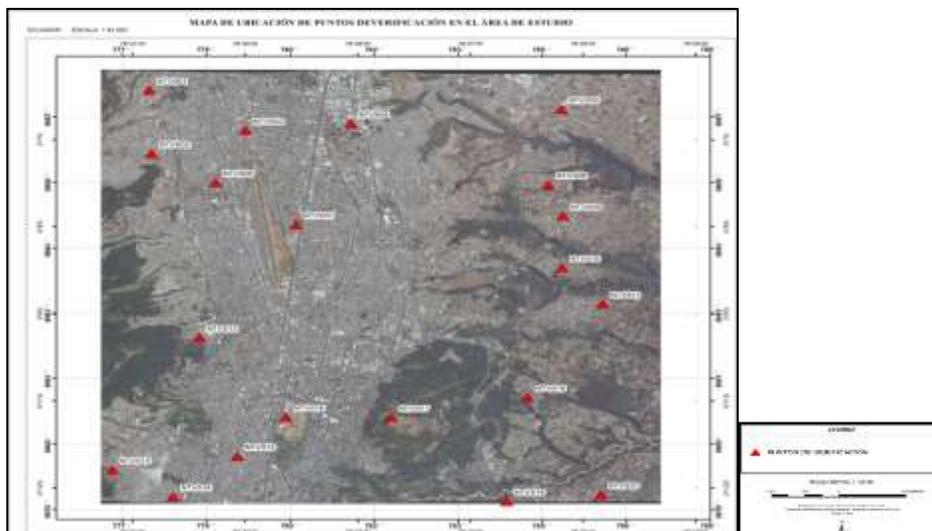
**Figura 11.**

*Propuesta de distribución de puntos de apoyo (GCP) por estéreo del año 2018*

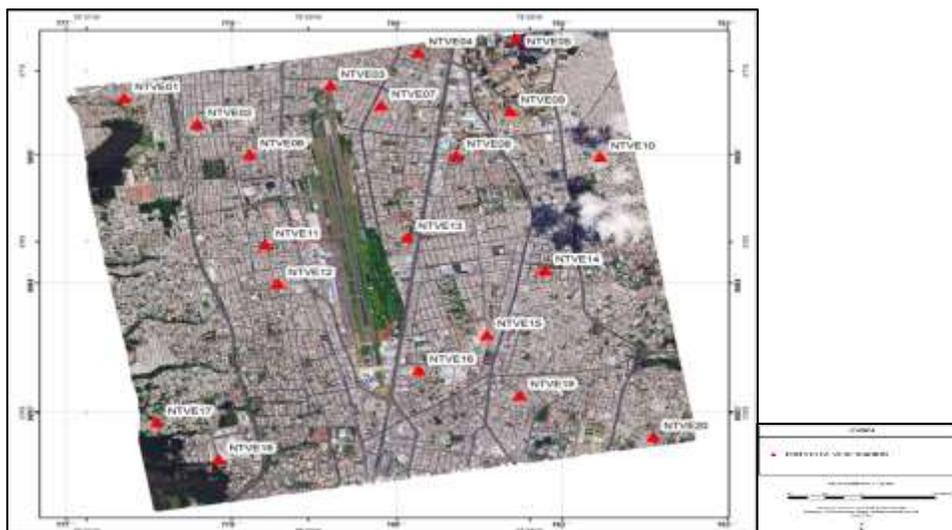


**Figura 12.**

*Distribución de puntos de validación de exactitud posicional por estéreo del año 2014*

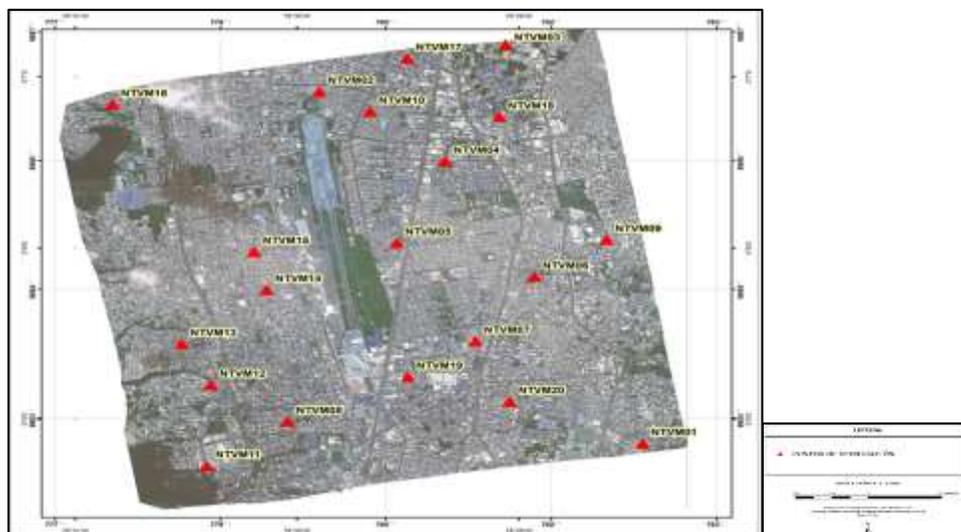
**Figura 13.**

*Distribución de puntos de validación de exactitud posicional por estéreo del año 2016*



**Figura 14.**

*Distribución de puntos de validación de exactitud posicional por estéreo del año 2018*



**Figura 15.**

*Distribución de puntos de validación de exactitud posicional para la cartografía*



### ***Reconocimiento en campo***

Se realizó el reconocimiento de campo para analizar la logística de llegada a cada punto, ver si cada punto marcado existe; de no ser el caso, poder replanificar su ubicación, también se analiza el tema de cantidad de equipos, tiempo de rastreo y distancias a recorrer; cabe mencionar que, los puntos a ser tomados deben ser fotoidentificados tanto en el año 2014, 2016 y 2018 con la finalidad de optimizar recursos.

### ***Toma de puntos de apoyo (GCP)***

Una vez verificada la propuesta de distribución de los puntos de apoyo con un reconocimiento de campo, se toman los puntos sin ninguna materialización en zonas planas y altas, tomando en cuenta la topografía del terreno; asimismo, se consideró el método de posicionamiento, las Estaciones de Monitoreo Continuo (EMC) más cercanas a los GCP, tiempo de posicionamiento, entre otras. Se planificó tomar 42 puntos en cada par estéreo; a partir de un receptor GNSS de doble frecuencia TRIMBLE R8, método NTRIP, por medio del servicio IP proporcionado por el IGM, cuya configuración se detalla en el Apéndice C. Los elencos de coordenadas resultantes se encuentran en el Capítulo IV.

### ***Toma de puntos de validación de exactitud posicional***

Los puntos de validación de exactitud posicional son puntos necesarios que se toman en campo con los criterios descritos en la planificación de toma de puntos de apoyo (GCP). Considerando el estudio y según la ASPRS, se requieren de 20 puntos aparte de los puntos de apoyo; cabe mencionar que estos puntos servirán para evaluar la exactitud posicional en las ortoimágenes. Los elencos de coordenadas resultantes se observan en el Capítulo IV.

***Evaluación de la precisión de puntos de apoyo (GCP) y puntos de validación de exactitud posicional***

Luego de la toma de puntos en campo, se procede a la evaluación de los GCP y puntos de validación mediante la ecuación 12, descrita en el Capítulo II. En este caso de estudio, la escala de la cartografía es 1:5000, por tanto la precisión de los GCP debe ser 0.5 m.

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

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

En la práctica, se usa la precisión planimétrica, por lo tanto la precisión de los GCP debe ser 0.375 m.

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

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

**Generación de Ortoimágenes**

El ajuste fotogramétrico se realiza en el programa LPS Core ERDAS 2014, donde se propuso la factibilidad de ortorrectificar imágenes satelitales estereoscópicas por dos modelos: Aerotriangulación combinada con los Coeficientes Polinomiales Racionales (RPC) y Aerotriangulación Directa.

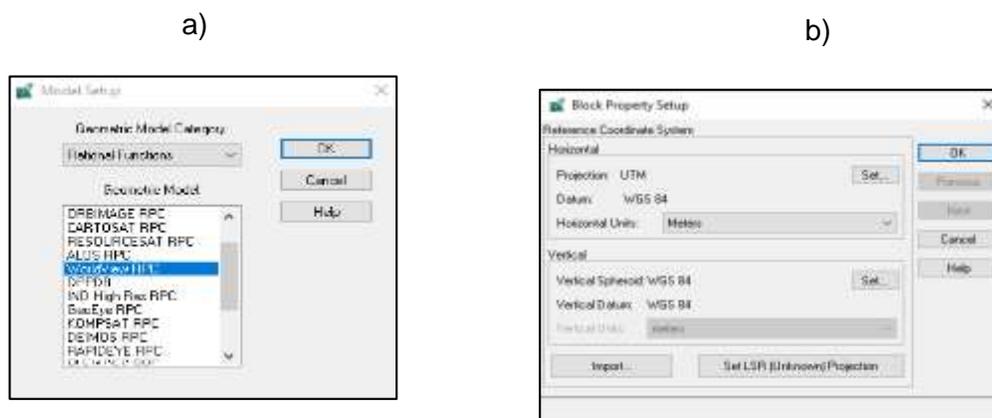
***Generación de ortoimágenes por aerotriangulación combinada con los Coeficientes Polinomiales Racionales (RPC)***

El procedimiento que se detalla a continuación se realizará para pruebas de ortorrectificación con 7, 9, 21, 30 y 42 puntos en cada uno de los pares estéreo, es decir, de los años 2014, 2016 y 2018. Los detalles de la generación de las ortoimágenes se encuentran en el Apéndice A. Los resultados del procesamiento se encuentran en el Capítulo IV. A continuación, se resume el procedimiento.

Iniciar con el módulo LPS del programa ERDAS 2014, escoger el modelo "Rational Functions"/" WorldView RPC", establecer el sistema de referencia, colocando UTM WGS84 Zona 17S, como se observa en la Figura 16, y finalmente cargar las imágenes a rectificar en formato .TIL.

**Figura 16.**

*Configuración del modelo del sensor y sistema de referencia*



*Nota.* a) Modelo del sensor, b) Sistema de referencia

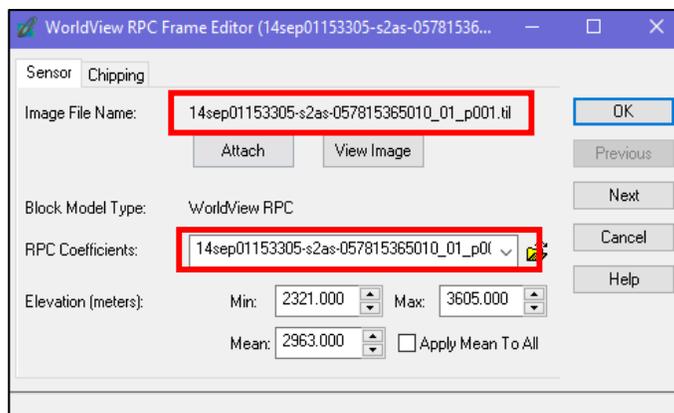
Configurado el modelo, continuar con las orientaciones, que se presentan:

### **Orientación Interior RPC**

Se procede a ejecutar los layer piramidales de las imágenes, una vez realizado el proceso, en la pestaña Edit/Frame Editor se observa que las imágenes cargadas estén en formato .TIL y a su vez se carga el archivo en formato .RPB, como se observa en la Figura 17.

**Figura 17.**

*Orientación interior del sensor WorldView*



### **Orientación exterior RPC**

Para desarrollar la orientación exterior, se escoge la herramienta Start point measurement tool, en su versión clásica, donde se visualiza una ventana en la que se pueden colocar los puntos de control (GCP) con sus respectivas herramientas, como se muestra en la Figura 18.

**Figura 18.**

*Entorno de trabajo para colocar puntos de control (GCP)*



Se importan los puntos tanto para X, Y y Z, tomando en consideración que en las opciones para coordenadas en type debe estar "Full" y en usage "Control". Una vez importados, se procede a seleccionar la herramienta Compute image coordinates from the ground points (ver Figura 19), y automáticamente se dibujan los puntos, pero se necesita ajustar a la posición en que fueron tomados en campo, como se observa en la Figura 20.

**Figura 19.**

*Herramienta Compute image coordinates from the ground points*



**Figura 20.**

*Ubicación de los puntos importados*



*Nota.* a) Punto ubicado automáticamente con la herramienta, b) Punto ajustado en la posición que fue tomado en campo.

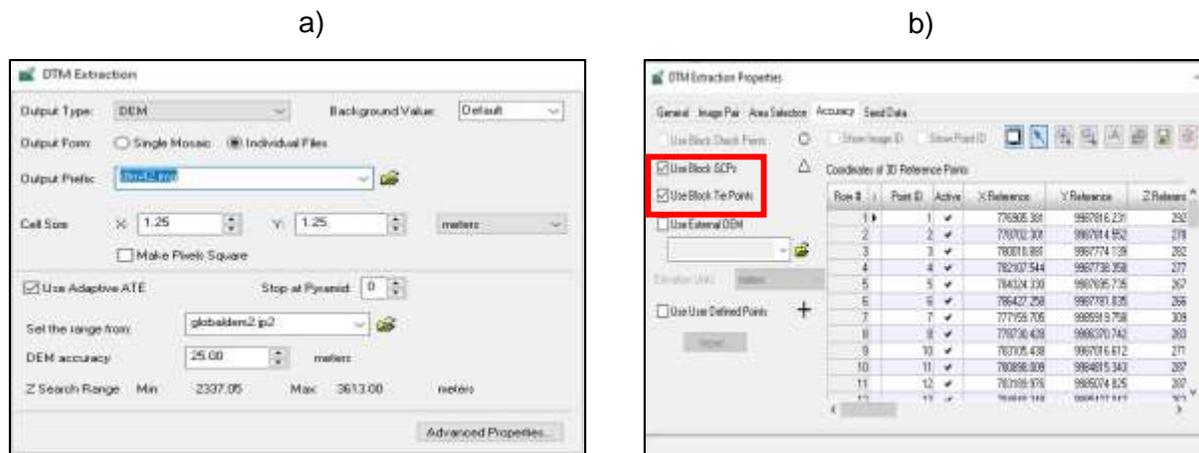
Después se ejecuta la generación de los tie points y finalmente, la aerotriangulación, cuyos resultados y reportes se detallan en el Capítulo IV.

### Generación de MDS por correlación con el modelo RPC

Una vez que se obtiene el ajuste, se puede generar en el módulo LPS Core ERDAS 2014 un Modelo Digital de Superficie (MDS) por correlación, para ello, se debe seleccionar la opción “DTM Extraction”/”Classic ATE” en donde se despliega una ventana en la que se configura “Advanced Properties” y en la pestaña “Accuracy” se activan los puntos de control y los tie points, como se observa en la Figura 21, para mayor detalle ver el Apéndice A, y los resultados en el Capítulo IV.

**Figura 21.**

*Parámetros de obtención de MDS*



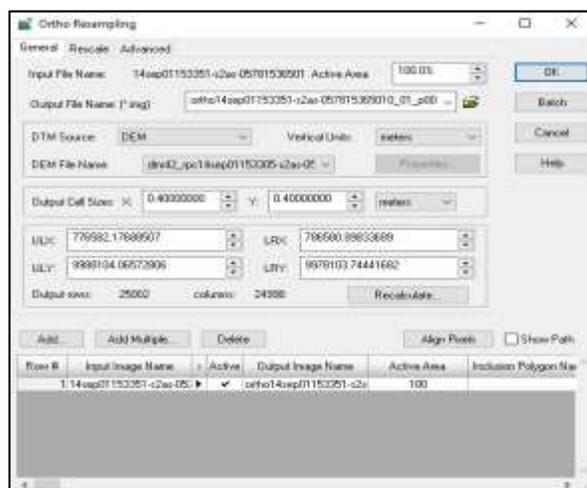
*Nota.* a) Parámetros obtención MDS, b) Activar puntos de control y tie points

### Generación de la ortoimagen con el modelo RPC

Finalmente, para generar la ortoimagen se necesita el ajuste más el Modelo Digital de Superficie (MDS), en donde se ingresan los parámetros como: nombre de salida, MDS, tamaño del pixel, entre otros, como se observa a continuación en la Figura 22.

**Figura 22.**

*Parámetros para la ortorrectificación de la imagen*



La ortoimagen resultante, ver en el Capítulo IV.

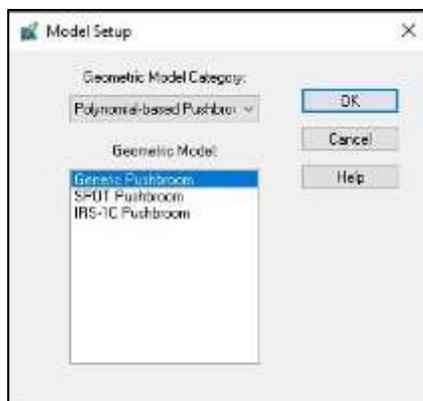
### ***Generación de ortoimágenes por aerotriangulación Directa***

El procedimiento que se detalla a continuación se realiza aplicando el modelo Polynomial Based in Pushbroom, esta es una alternativa si no se cuenta con el archivo .RPB. De la misma manera, que el proceso anterior, se realiza pruebas de ortorrectificación con 7, 9, 21, 30 y 42 puntos; en este caso se realiza con el par estéreo del año 2016. La elaboración de las ortoimágenes por este modelo es detallada en el Apéndice B. Los resultados del procesamiento se encuentran en el Capítulo IV. A continuación, se generaliza el procedimiento aplicado:

Iniciar con el módulo LPS del programa ERDAS 2014, escoger el modelo "Polynomial Based in Pushbroom"/"Generic Pushbroom", establecer el sistema de referencia, colocando UTM WGS84 Zona 17S, como se observa en la Figura 23, y finalmente, cargar las imágenes a rectificar en formato .TIL.

**Figura 23.**

*Configuración del modelo del sensor*



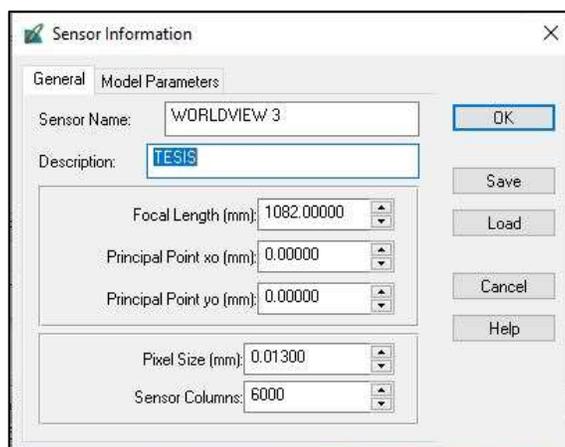
Configurado el modelo, se procede con las orientaciones:

### **Orientación interior Aerotriangulación Directa**

Se procede a ejecutar los layer piramidales, una vez realizado el proceso, en la pestaña Edit/Frame Editor se accede a la información del sensor que permite llevar a cabo la orientación interior de cada imagen; seleccionar el nombre del sensor (WorldView), si el sensor no existe crear uno nuevo como se observa en la Figura 24.

**Figura 24.**

*Orientación interior y creación de parámetros del sensor WorlView*



Se dejaron los valores por defecto, aunque es importante recalcar que los parámetros deben ser actualizados con los verdaderos valores del sensor WorldView, ya que en esta versión de ERDAS no se encuentran.

### **Orientación exterior Aerotriangulación Directa**

Para desarrollar la orientación exterior, se escoge la herramienta Start point measurement tool, en su versión clásica, donde se visualiza una ventana en la que se colocan los puntos de control (GCP) con sus respectivas herramientas, como se muestra en la Figura 25.

**Figura 25.**

*Entorno de trabajo para colocar puntos de control (GCP)*

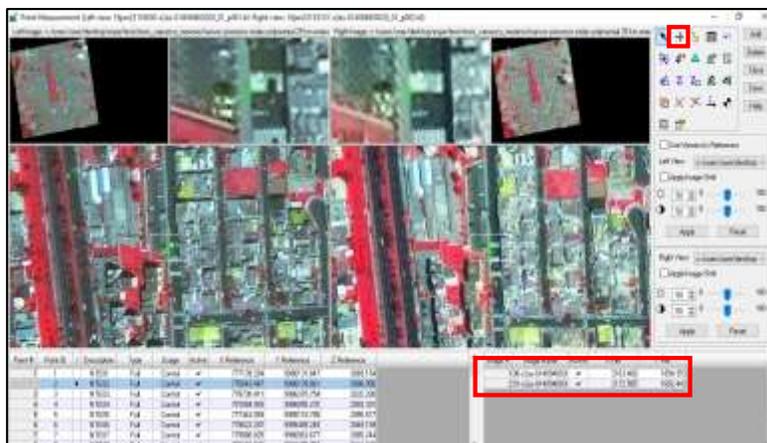


### **Marcado de GCP**

Con la finalidad de orientar las imágenes en su posición georeferenciada, se selecciona la herramienta "Create Point", se busca la ubicación del punto con respecto a la fuente de referencia y se marca el punto en cada una de las imágenes, como se observa en la Figura 26; una vez realizado el proceso se puede observar en la parte inferior derecha del entorno de trabajo las coordenadas de imagen del punto pinchado; este proceso de debe llevar acabo con los demás puntos.

**Figura 26.**

*Marcado de puntos de apoyo (GCP)*



Se importan los puntos tanto para X, Y y Z, tomando en consideración que, en las opciones para coordenadas, en type debe estar “Full” y en usage “Control”, como se observa en la Figura 27.

**Figura 27.**

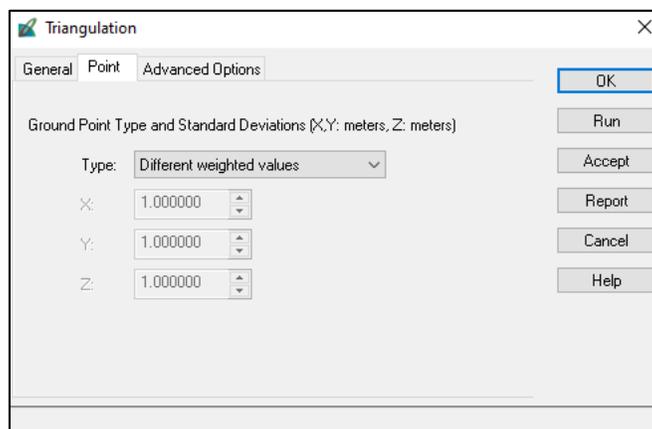
*Importación de coordenadas de referencia*

Point #	Point ID	Description	Type	Usage	Active	X Reference	Y Reference	Z Reference
1	1	NTE01	Full	Control	✓	777133.294	9396131.847	3069.154
2	2	NTE02	Full	Control	✓	778043.847	9396133.961	2896.956
3	3	NTE03	Full	Control	✓	778730.411	9396370.754	2832.280
4	4	NTE04	Full	Control	✓	781084.983	9396855.270	2983.391
5	5	NTE05	Full	Control	✓	777442.059	9395118.795	2955.577
6	6	NTE06	Full	Control	✓	779622.267	9395489.245	2949.189
7	7	NTE07	Full	Control	✓	779980.825	9396063.677	2862.244
8	8	NTE08	Full	Control	✓	780583.066	9396275.753	2946.330

Cabe mencionar que al momento de generar los tie points se pudo observar que el error medio cuadrático subía a 2.408 pixel, como alternativa, se decide no trabajar con los tie points notándose que baja el RMSE a 0.0476 pixel, pero la prueba de convergencia igualmente no se supera; al respecto, para procesar, se decide modificar los pesos de los puntos en la viñeta “Point” como se observa en la Figura 28.

**Figura 28.**

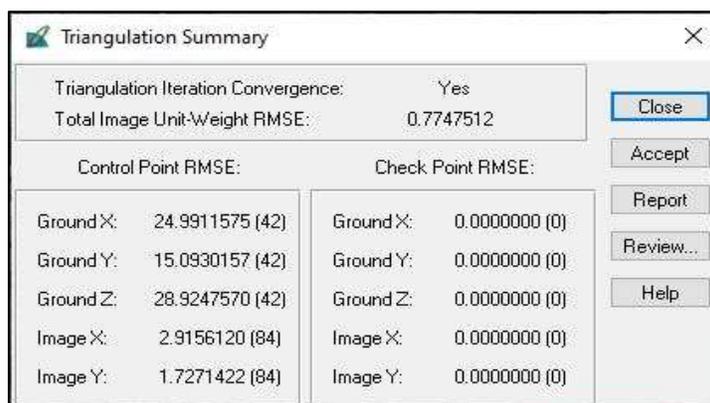
*Modificación de los pesos de cada punto en la Aerotriangulación*



Una vez que se cambian los pesos de los puntos, se corre nuevamente la Aerotriangulación y observa que la convergencia fue superada, como se muestra en la Figura 29.

**Figura 29.**

*Aerotriangulación de la ortoimagen modelo Polynomial Based in Pushbroom*

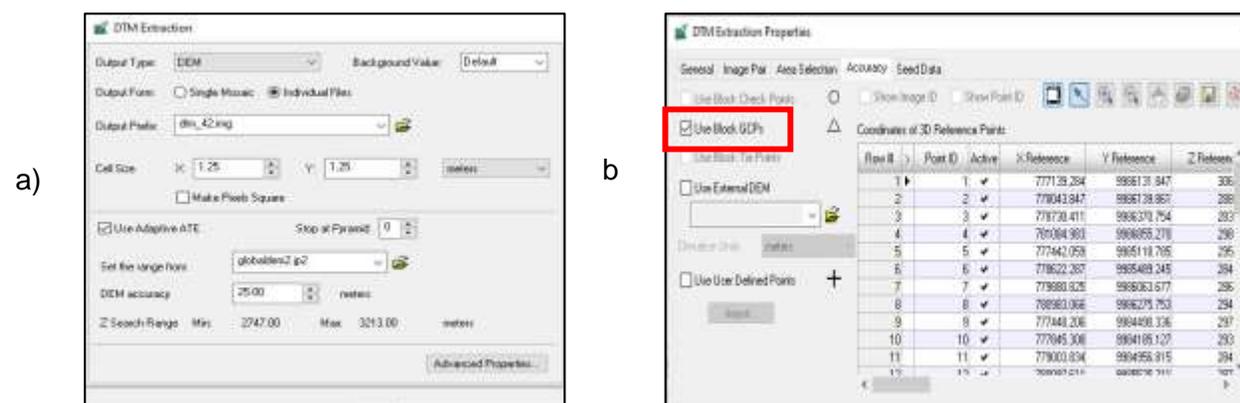


## Generación MDS por correlación con el modelo Polynomial Based in Pushbroom

Al igual que el MDS del modelo RPC, se siguen los mismos pasos y parámetros como se observa en la Figura 30, los resultados se encuentran en el Capítulo IV.

**Figura 30.**

*Parámetros para obtención de MDS*



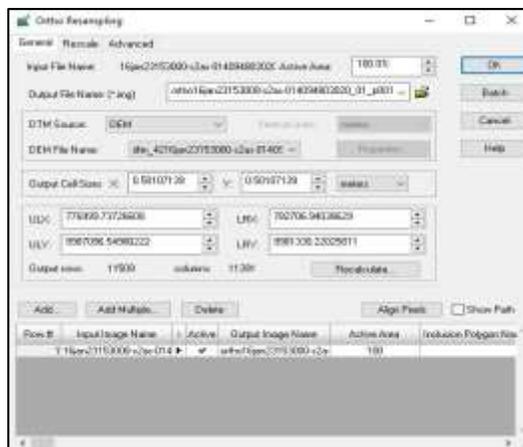
*Nota.* a) Parámetros obtención MDS, b) Activar puntos de control

## Generación de la ortoimagen con el modelo Polynomial Based in Pushbroom

Finalmente, para generar la ortoimagen se necesita el ajuste más el Modelo Digital de Superficie (MDS), en donde se ingresan los parámetros como: nombre de salida, MDS, tamaño del pixel, entre otros., a continuación se ilustran en la Figura 31, cuyos resultados se detallan en el Capítulo IV.

**Figura 31.**

*Parámetros para la ortorrectificación de la imagen*



### **Exactitud espacial de los productos derivados del ajuste**

En este proceso se realizó una evaluación para los productos 2D y 3D, en el caso de las ortoimágenes, se partió de un análisis empleando los estadísticos media, desviación estándar, el máximo y mínimo, la que se llamará estadística clásica. De igual manera se empleó la política del Instituto Geográfico Militar (IGM) y la norma NSSDA, la que se llamará estadística normativa; considerando esta última, en el empleo de la evaluación del Modelo Digital de Superficie. A continuación se detalla el desarrollo de la aplicación de la política del IGM y la norma NSSDA.

### **Evaluación exactitud posicional planimétrica normas NSSDA e IGM de las ortoimágenes**

En la evaluación de las ortoimágenes se procedió a crear un shapefile que consta de 20 puntos de validación tomados en campo, para cada una de las imágenes. Luego, en la comparación se creó un shapefile en cada producto generado, es decir, en las ortoimágenes con 7 GCP, 9GCP, 21 GCP, 30 GCP y 42 GCP respectivamente. Después se marcaron 20 puntos en los sitios homólogos de cada ortoimagen.

Con la aplicación de la herramienta de proximidad “Near” en ArcMap se calculó la distancia existente entre el punto de referencia y su homólogo en la ortoimagen, permitiendo obtener los estadísticos: media, desviación estándar, el máximo y mínimo; los resultados se detallan en el Capítulo IV.

Asimismo, se aplica la norma National Standard for Spatial Data Accuracy (NSSDA) al 95% de confianza, haciendo uso de las ecuaciones 1, 2, 3 y 5, para lograr alcanzar la exactitud posicional planimétrica, y de la misma manera se aplicó la norma IGM al 90% de confianza, haciendo uso de la ecuación 9.

Los elencos de coordenadas comparativas descritas en el Capítulo IV, servirán de insumo para realizar la evaluación de la exactitud posicional en las ortoimágenes.

Aplicando la norma NSSDA, se calcula lo siguiente:

$$RMSE_x = \sqrt{\frac{4.207}{20}}$$

$$RMSE_x = 0.459 \text{ m}$$

$$RMSE_y = \sqrt{\frac{3.028}{20}}$$

$$RMSE_y = 0.389 \text{ m}$$

$$RMSE_r = \sqrt{\frac{4.207 + 3.029}{20}}$$

$$RMSE_r = 0.601 \text{ m}$$

Caso 2: si  $RMSE_x \neq RMSE_y$  se aplica la ecuación (5):

$$\text{Exactitud } r = 2.4477 \times 0.5 \times (0.459 + 0.389)$$

$$\text{Exactitud } r = 1.037 \text{ m}$$

Aplicando la norma IGM, se calcula lo siguiente:

Caso 2: cuando  $RMSE_x \neq RMSE_y$ , la exactitud posicional se calculará de la siguiente manera:

$$\text{Exactitud } r = 2.1460 \times 0.5 \times (0.459 + 0.389)$$

$$\text{Exactitud } r = 0.91 \text{ m}$$

El mismo proceso se sigue para todos los productos generados, los resultados obtenidos se encuentran en el Capítulo IV.

Con respecto a la exactitud planimétrica, se debe tener en cuenta la tolerancia presentada en la norma IGM, descrita en la ecuación 10, tomando en cuenta el Módulo de la Escala para 1:5000 que es de 5 m.

$$PH = 0.3mm * 5$$

$$PH = 1.5 \text{ m}$$

### **Evaluación exactitud posicional altimétrica de los MDS**

En cuanto a la exactitud altimétrica, se calcula el valor de altitud del ráster (MDS) generado en la obtención de ortoimágenes, a través de la herramienta “Extract Value to Points” de ArcMap, preparándose una tabla con los valores de altura, tal como se muestra en la Figura 32.

Figura 32.

Valores de altura del MDS

FID	Shape *	Id	NORTE	ESTE	NEAR_FID	NEAR_DIST	RASTERVALU
0	Point	0	9907020.29644	777478.202202	0	0.277096	2001.224609
1	Point	0	9906159.88403	777522.681923	1	0.226325	2981.095459
2	Point	0	9906895.89507	779199.904068	2	0.608353	2609.505127
3	Point	0	9906847.08067	781803.862836	3	0.273096	2984.144531
4	Point	0	9907176.68569	784837.867266	4	0.478932	2661.534424
5	Point	0	9905502.68051	778682.700018	5	0.229394	2847.415283
6	Point	0	9904534.68010	780907.462932	6	0.462394	2839.43447
7	Point	0	9905445.50259	784607.842485	7	0.202379	2636.262695
8	Point	0	9904732.3192	784869.102485	8	0.789394	2641.395508
9	Point	0	9903542.67363	784852.689436	9	0.222478	2633.399629
10	Point	0	9902712.3107	785504.689682	10	0.283296	2596.466553
11	Point	0	9901939.09798	778373.080264	11	0.033897	2932.281006
12	Point	0	9978905.94171	776816.661104	12	1.9322	2994.140301
13	Point	0	9978283.49137	777903.062957	13	0.968301	2864.421631
14	Point	0	9979216.78722	779053.079213	14	0.296394	2833.636865
15	Point	0	9908113.51101	779919.489874	15	0.25489	2888.833008
16	Point	0	9909107.89026	781805.51125	16	0.271897	2946.802246
17	Point	0	9909599.49886	784238.706414	17	0.173342	2612.588623
18	Point	0	9978180.72015	783885.083479	18	0.27448	2502.84375
19	Point	0	9978320.8966	785545.667177	19	0.60621	2422.894287

Una vez obtenidos los valores, se calculó la diferencia entre la altura elipsoidal del punto tomado en campo con respecto al extraído del MDS generado, aplicando las fórmulas 6 y 7 descritas en el Capítulo II pertenecientes a la norma National Standard for Spatial Data Accuracy (NSSDA); se obtiene el RMSEz y la Exactitud r.

Aplicando la norma NSSDA, se calcula lo siguiente:

$$RMSE_z = \sqrt{\frac{19.778}{20}}$$

$$RMSE_z = 0.994 \text{ m}$$

$$Exactitud_v = 1,96 * 0.994$$

$$Exactitud_v = 1.949 \text{ m}$$

El mismo proceso se sigue para todos los productos generados.

Hay que tener en cuenta la tolerancia presentada en la norma IGM, descrita en la ecuación 11, tomando en cuenta el intervalo de curva para 1:5000 que es de 5 m.

$$PV = \frac{1}{4} * 5 m$$

$$PV = 1.25 m$$

Los resultados obtenidos de la evaluación altimétrica en el Capítulo IV.

### **Generación de Cartografía**

La cartografía se realizará en los programas ArcMap y en ArcGIS Pro, con licencias otorgadas por la Universidad de las Fuerzas Armadas ESPE; se obtendrá cartografía mediante digitalización y Deep Learning de la ortoimagen de 100km<sup>2</sup> con 42 GCP del año 2014, se utilizó esta ortoimagen debido a que posee un menor nadir (13.1°) con respecto a las de los años 2016 y 2018, además que cumple con la precisión horizontal clásica y con las normas IGM y NSSDA como se indica en el Capítulo IV.

### **Generación de Cartografía por Digitalización**

En este proceso se va a digitalizar sobre la ortoimagen de 100 km<sup>2</sup> del año 2014 en el Software ArcMap; se tomarán en cuenta los atributos asociados al catálogo de objetos del Instituto Geográfico Militar para escala 1:5000; por lo cual se tomará un área de 200ha aproximadamente para realizar este proceso, adicional se generará una GDB con los atributos digitalizados, tal como se muestra en la Tabla 6.

**Tabla 6.***Elementos digitalizados en el proceso de generación de cartografía*

<b>N°</b>	<b>Feature Class</b>	<b>Categorías</b>	<b>Subcategorías</b>	<b>Descripción</b>
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 vehículos terrestres.
7	via_ruta_l	Infraestructura de transporte	Transporte Terrestre	Espacio destinado al tránsito de vehículos terrestres.
8	arbol_p	Cobertura de la Tierra	Tierras forestales	Plantas perennes, de tronco leñoso, posee una altura considerable.

Fuente: Catálogo de objetos, Instituto Geográfico Militar

*Nota.* Los elementos canchas, edificaciones, manzanas y área poseen la geometría tipo polígono, árboles geometría tipo punto; y vías posee dos tipos de geometría polígono y línea

Como se mencionó en el Capítulo II, la topología es una colección de reglas que permite modelar y corregir las relaciones geométricas de las GDB, permitiendo identificar errores en las capas, por lo cual a partir de la digitalización de las ortoimágenes se realizará una revisión topológica de puntos, líneas y polígonos, en los cuales se aplicarán las siguientes reglas topológicas:

Líneas:

- Must not overlap
- Must not intersect
- Must not have dangles
- Must not have pseudo-nodes

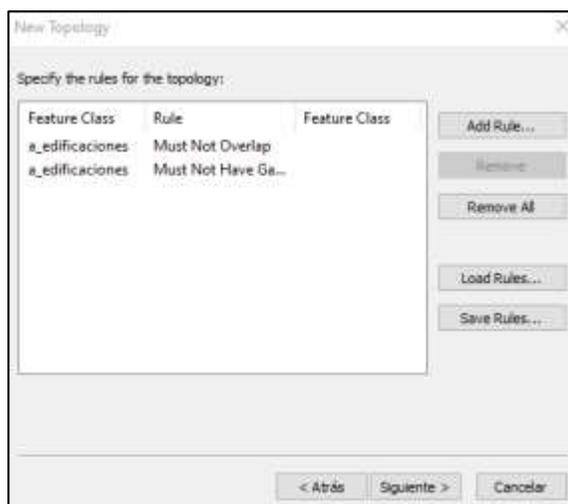
Polígonos:

- Must not overlap
- Must not have gaps

La topología se la crea desde ArcCatalog, dentro del Dataset que contiene la capa involucrada, por cual se empezará por la capa de edificaciones, en la Figura 33, se puede observar las reglas topológicas aplicadas a una capa de polígonos:

### Figura 33.

*Creación de las reglas de topología*



Al generar el informe se observan los errores dentro de las reglas topológicas seleccionadas. Hay que tener en cuenta que no todos son errores, ya que algunos muestran

los bordes de los polígonos, por lo que se les colocará como excepciones. El resultado de la generación de cartografía por digitalización se encuentra en el Capítulo IV.

### **Generación de Cartografía por Deep Learning**

La metodología completa aplicada para la generación de cartografía por Deep Learning se encuentra detallada en el Apéndice D.

### **Software utilizado para la generación de Cartografía por Deep Learning**

ArcGIS Pro es el software con el cual se generó cartografía con Deep Learning, su licencia fue facilitada por la Universidad de las Fuerzas Armadas ESPE, distribuidor autorizado de tecnología de ESRI.

### **Requerimientos del sistema para instalar ArcGIS Pro**

Existen varios requerimientos que una máquina ya sea virtual o física debe cumplir para que el software sea ejecutado con normalidad. ArcGIS Pro es compatible con varios sistemas operativos Microsoft Windows, que van desde Windows Server 2012 Standard y Datacentres de 64 bits hasta Windows 11 Home, Pro y Enterprise de 64 bits, ArcGIS Pro es compatible hasta la última actualización de mayo de 2022. Los requisitos de hardware se mencionan en la Tabla 7.

**Tabla 7.**

*Requisitos de hardware para instalar ArcGIS Pro*

<b>N°</b>	<b>Elemento</b>	<b>Mínimo</b>	<b>Recomendación</b>	<b>Óptimo</b>
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

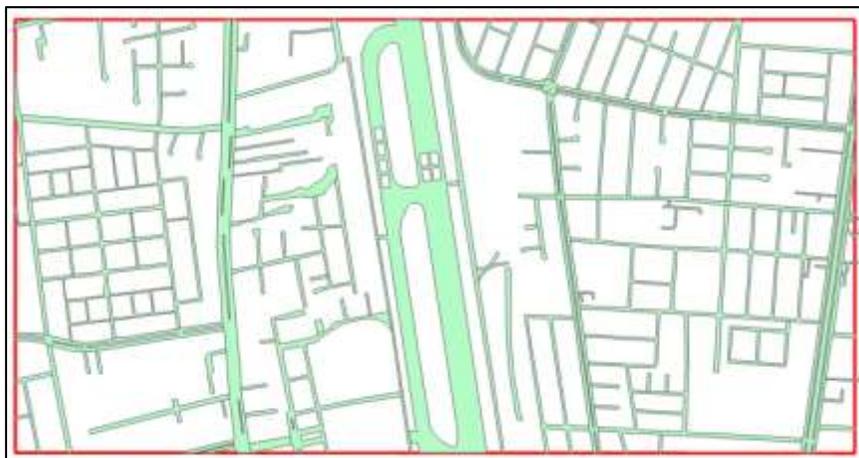
Fuente: (ESRI, 2022)

### Definición de las clases

Una vez instalado el software, se procede a la definición de las clases que se van a generar por Deep Learning, en las que se encuentran: vías, manzanas y edificaciones (techos), para lo cual se ejecutarán varios entrenamientos dentro de ArcGIS Pro, que permitirán clasificar los píxeles y generar la cartografía. En las Figuras 34, 35 y 36 se pueden visualizar las muestras para vías, manzanas y edificaciones respectivamente.

**Figura 34.**

*Muestra de polígonos de vías para modelo de entrenamiento*

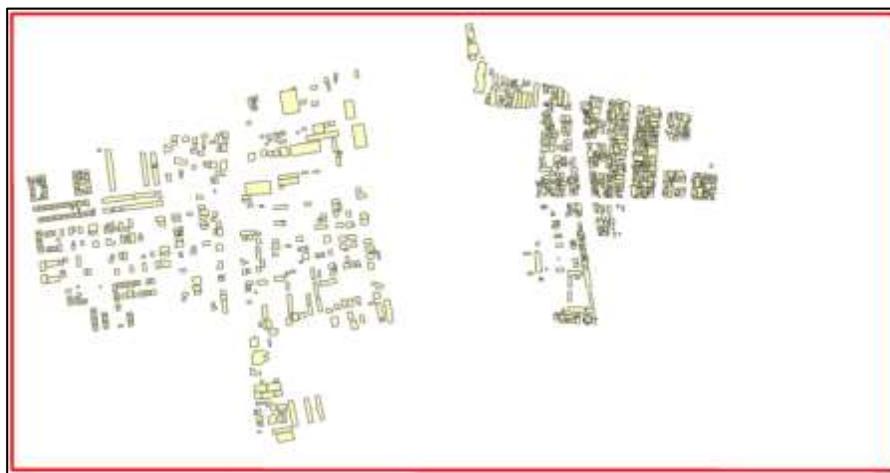
**Figura 35.**

*Muestra de polígonos de manzanas para modelo de entrenamiento*



**Figura 36.**

*Muestra de polígonos de edificaciones para modelo de entrenamiento*



*Nota.* Como se puede observar en la Figura 36, se tiene 2 tipos de muestras, una muestra con polígonos separados y una muestra con polígonos juntos, lo que permitirá aplicar el método experimental al generar cartografía utilizando Deep Learning.

**Segmentación de imagen**

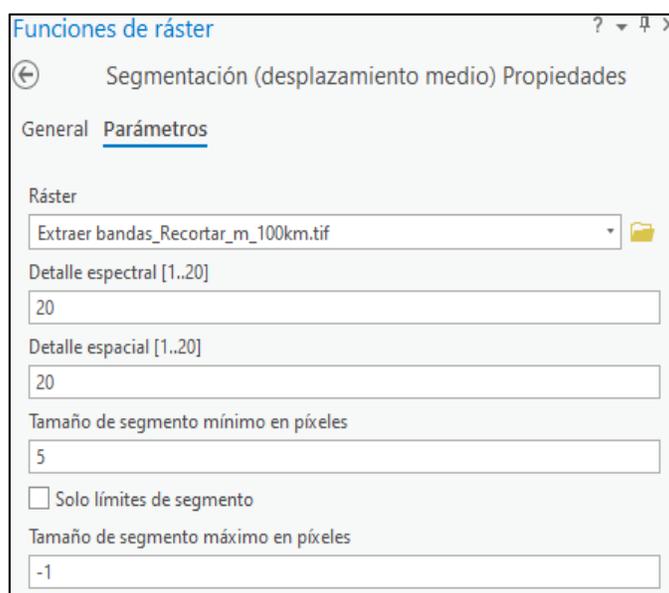
En la Figura 7, apartado g; se detalla el proceso a seguir para la generación de cartografía con Deep Learning en el software ArcGis Pro, como se menciona en el Capítulo II la segmentación permite agrupar una imagen en varios grupos de píxeles que poseen características similares entre sí, tales como color, textura, patrones, entre otros.

Por lo cual en el Software ArcGIS Pro dirigirse a *Imágenes, Funciones de ráster, Clasificación, Segmentación (desplazamiento medio)*. 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 a realizar y la cantidad de detalle que se desea extraer, en este caso de estudio se ha aplicado diferentes valores en la herramienta, con la finalidad de obtener una imagen con la cual se pueda aplicar

los modelos de entrenamiento. En la Figura 37, el valor máximo que se ha colocado es de 20 en el detalle espectral y espacial lo cual permitirá generar una imagen en la que se puedan discriminar las clases por contraste, colores, entre otros. Mientras que en el Tamaño de segmento mínimo se colocó el valor de 5 mismo que se relaciona con la unidad mínima a cartografiar y con lo que se desea obtener. El resultado de la segmentación se encuentra en el Capítulo IV.

### Figura 37.

#### *Herramienta de segmentación de la imagen*



*Nota.* Tomar en cuenta que para realizar este proceso es necesario contar con una imagen de máximo 3 bandas, en caso de tener una imagen con más bandas se recomienda aplicar la herramienta *Extraer bandas*.

Exportar la información generada en el paso anterior a un ráster de tipo 8 bits unsigned, en formato de archivo de salida colocar TIF, como se muestra en la Figura 38.

**Figura 38.**

*Exportar ráster de segmentación*

**Extracción de datos de entrenamiento**

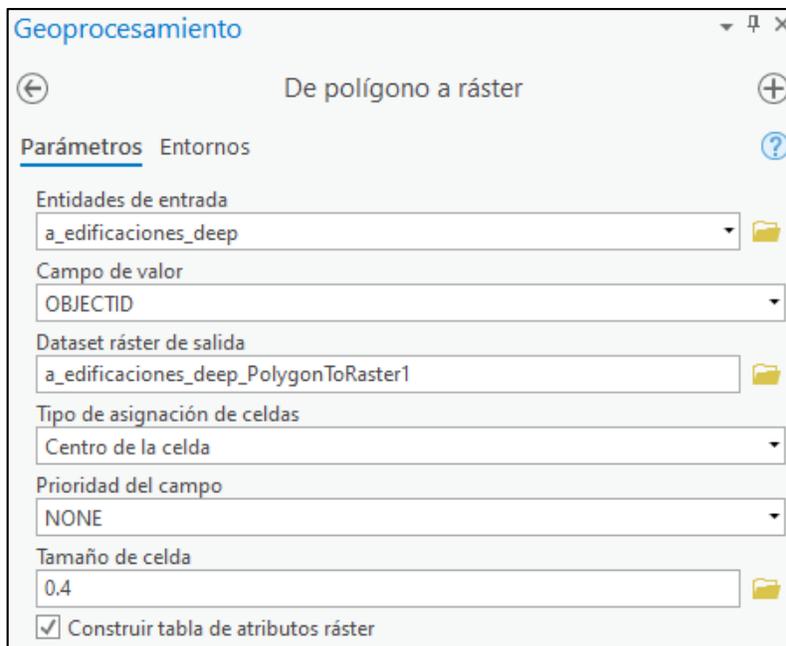
En este proceso, se realizará el entrenamiento del modelo para la extracción de vectores, por lo tanto en el Software ArcGIS Pro, en la barra de herramientas seleccionar *Análisis, Herramientas, Caja de herramientas, Herramientas de conversión, A ráster*. Colocar como entidad de entrada, la muestra de polígonos digitalizados dentro del área de 200 ha en formato shapefile, en este caso se colocará la muestra de edificaciones de la Figura 36.

En tipo de asignación de celda se colocará *Centro de la celda* que indica que el valor de la celda se asignará al polígono que se superpone a la celda; mientras que en tamaño de

celda, se ha dejado el tamaño de píxel de la ortoimagen de 100 km<sup>2</sup> del año 2014, mismo que es 0.4 m, ver Figura 39.

### Figura 39.

*Extracción de datos de entrenamiento – Geoprocésamiento de polígono a ráster*



*Nota.* Dejar por defecto la ubicación del ráster de salida.

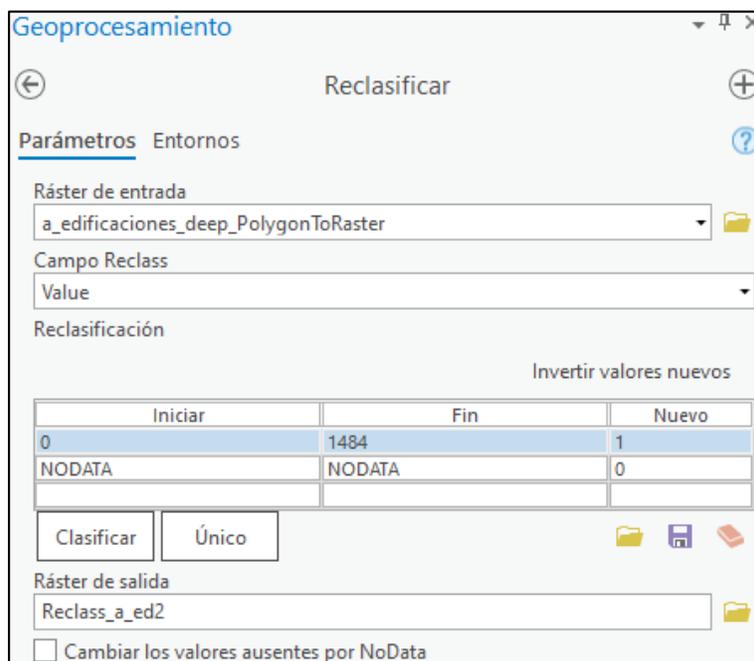
### Reclasificación de los datos de entrenamiento

Se procedede a hacer una reclasificación; para lo cual, en la barra de herramientas seleccionar Análisis, Herramientas, Caja de herramientas, Herramientas de spatial analyst, Reclassificar, Reclassificar.

El campo que se utilizará en la relcasificación es en campo Value, clasificar el ráster de entrada, tomar en cuenta que el número de clases es de 1 y en los valores finales colocar en NO DATA el valor 0, ver Figura 40.

**Figura 40.**

*Reclasificación de los datos de entrenamiento*

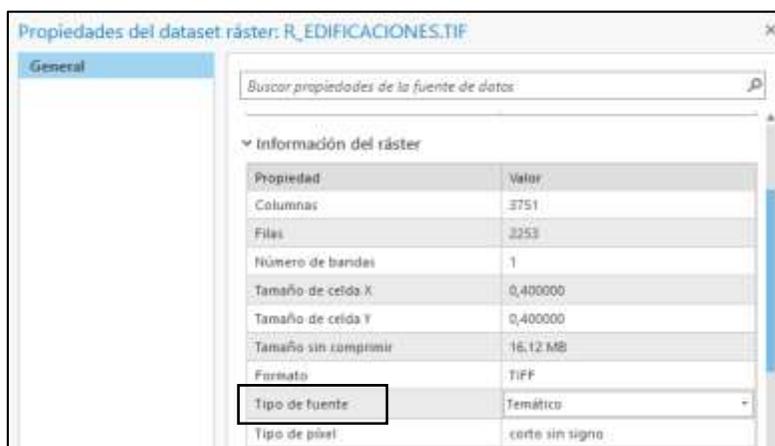


*Nota.* Dejar por defecto la ubicación del ráster de salida.

El resultado de la reclasificación de los datos de entrenamiento se encuentra en el Capítulo IV. Exportar la información generada en el paso anterior a un ráster de tipo 8 bits unsigned, en la barra de herramientas seleccionar *Vista, Vista de catálogo*, buscar el archivo de reclasificación, abrir sus *Propiedades* dentro de las cuales dirigirse a *Información del ráster*, en *Tipo de fuente*, verificar que este sea de tipo *Temático*, caso contrario cambiarlo, como se indica en la Figura 41. El tipo de fuente temático permite visualizar los ráster con datos geográficos transmitiendo información extra en las entidades geográficas representando por ejemplo información del uso de la tierra.

**Figura 41.**

*Propiedades del dataset ráster*



## Exportar datos de entrenamiento

Esta herramienta permitirá generar pequeñas subimágenes denominadas “chips”, mismas que van a contener varias características que le permitirán al modelo aprender.

Para exportar los datos de entrenamiento dirigirse a la barra de herramientas, seleccionar *Análisis, Herramientas, Caja de herramientas, Image analyst tools, Deep Learning, Export training data for deep learning*. Se desplegará una ventana, en la cual se colocará como dato de inicio al *ráster de Segmentación*, dentro de *Input Feature Class or Classified Raster or Table* se colocará la reclasificación de los polígonos de muestra. En *Metadata format* se escogerá *Classified Tiles*, esto debido a que los archivos de salida generarán más estadísticas e información que los otros formatos; adicional este formato es utilizado para detección de cambios y clasificación de píxeles, ver Figura 42.

**Figura 42.**

*Modelos de entrenamiento*

The screenshot shows the 'Export Training Data For Deep Learning' tool interface. The title bar indicates the tool is part of the 'Geoprocésamiento' (Geoprocessing) environment. The tool name is 'Export Training Data For Deep Learning'. The interface is divided into 'Parámetros' (Parameters) and 'Entornos' (Environments) tabs. The 'Parámetros' tab is active, showing the following settings:

- Input Raster:** SEGMENTACION.tif
- Additional Input Raster:** (Empty)
- 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

*Nota.* Colocar la dirección del *Output Folder* al final.

En *Entornos* colocar en *Tamaño de celda* el valor de 0.4.

### **Entrenamiento del modelo**

Con la finalidad de entrenar los modelos se utiliza la herramienta *Train Deep Learning Model*, por lo cual para este proceso dirigirse a la barra de herramientas seleccionar *Análisis, Herramientas, Caja de herramientas, Image analyst tools, Deep Learning, Train Deep Learning*

*Model*. Dentro de *Input Training Data* se colocarán las carpetas que contienen los chips que corresponden a los datos de entrenamiento, el *número de épocas (max epochs)* indica cuantas veces el modelo aprenderá una característica antes de pasar a otra; en *Model Type* se colocará *UNet* ya que permite entrenar el modelo mediante la clasificación de píxeles

Adicionalmente se puede probar con los modelos: *Detector de bordes BDCN* y *Detector de borden HED*, ya que facilitan la detección de bordes y límites de objetos a diferentes escalas, para carreteras se puede utilizar *Extractor de carreteras multitarea* y *ConnectNet*.

En *Bach Size*, se colocará el número de muestras de entrenamiento, sin embargo hay que tener en cuenta que a medida que aumenta el número de lotes aumenta el consumo de memoria y puede generar un error durante el proceso, en *Backbone Model* se colocará ResNet-152, mismo que representa un modelo preconfigurado que contine en su base más de un millón de imágenes guía y 152 capas de profundidad las cuales permitirán generar un mejor modelo de aprendizaje.

En esta herramienta es indispensable seleccionar *Stop when model stops improving* con la finalidad de que el proceso se detenga una vez que el modelo ha dejado de aprender, lo cual evita pérdidas de tiempo y de memoria del equipo en el cual se esté desarrollando el modelo, ver Figura 43.

Figura 43.

*Entrenamiento del modelo*

Geoprocesamiento

Train Deep Learning Model

Parámetros Entornos

Input Training Data  
CHIPS1

Output Model  
MODELO

Max Epochs 200

Model Parameters

Model Type  
U-Net (Pixel classification)

Batch Size 8

Model Arguments

Name	Value
class_balancing	False
mixup	False
focal_loss	False
ignore_classes	
chip_size	224

Advanced

Learning Rate

Backbone Model  
ResNet-152

Pre-trained Model

Validation % 10

Stop when model stops improving

Freeze Model

*Nota.* Colocar la dirección del *Output Model* al final. Se utilizará ResNet-34 y ResNet-152.

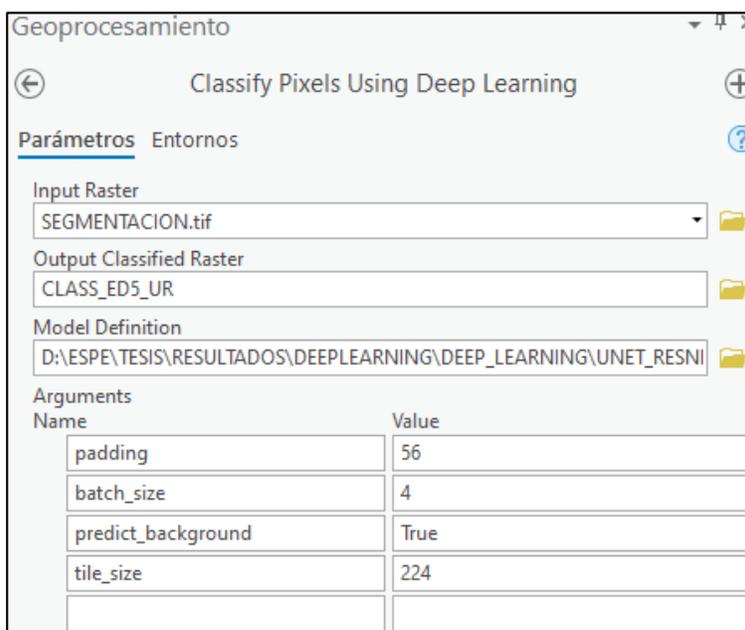
### Extracción de clasificación del ráster usando Deep Learning.

Para este proceso dirigirse a la barra de herramientas seleccionar *Análisis, Herramientas, Caja de herramientas, Image analyst tools, Deep Learning, Classify pixels using*

*Deep Learning*. En Input Raster colocar el ráster que corresponde a la segmentación, en Output Classified Raster, colocar la carpeta en la que se guardará la clasificación y en Model Definition colocarel archivo .emd mismo que corresponde a los chips, ver Figura 44.

#### Figura 44.

*Clasificación de píxeles para identificación de edificios*



#### Generalización de los datos de clasificación por Deep Learning

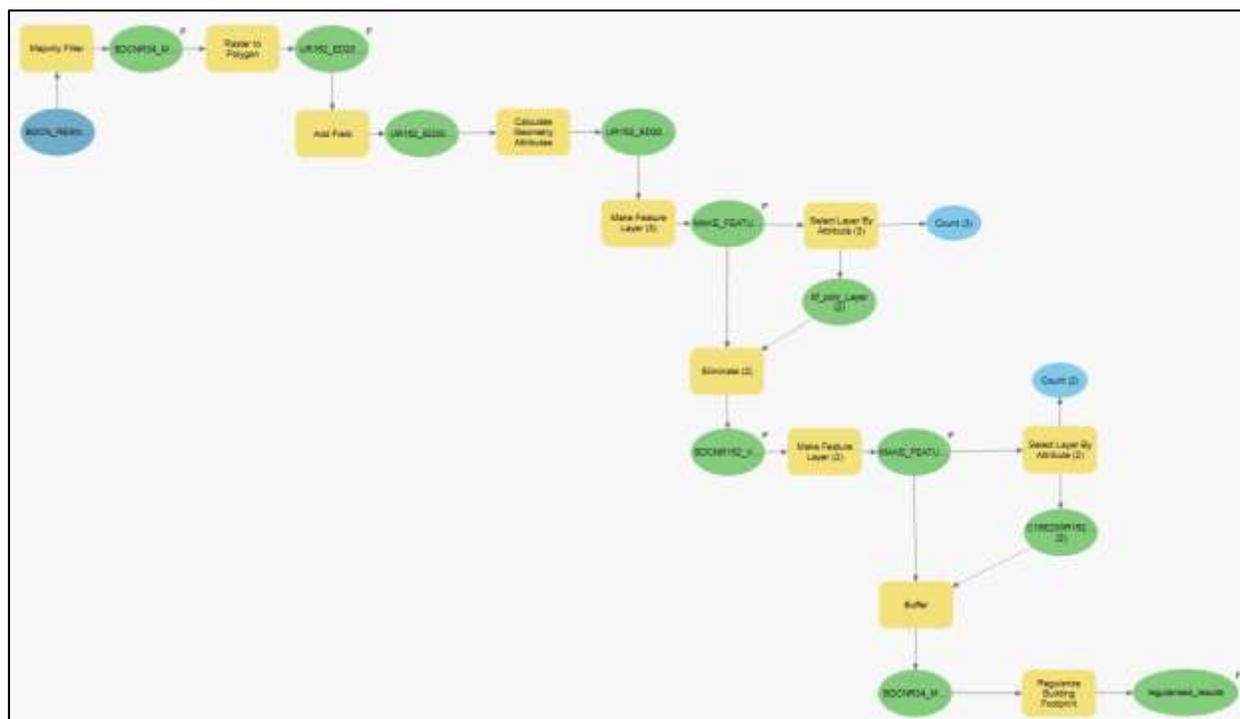
En este proceso, se tomarán en cuenta los datos de clasificación, mismos que tendrán que ser procesados para poder obtener mejores resultados, por lo tanto se propone el uso de un modelo diseñado en Model Builder, en la cual se detallan las características y herramientas que permitirán generalizar los vectores de la extracción. Dentro de este modelo (ver Figura 45) se encuentran las siguientes herramientas:

- Majority Filter
- Raster to Polygon

- Add Field
- Calculate Geometry Attributes
- Make Feature Layer
- Select Layer by Attribute
- Eliminate
- Buffer
- Regularize Building Footprint

**Figura 45.**

*Herramienta de generalización en Model Builder*



Una vez aplicado el modelo de generalización, se procederá a pasar las reglas de topología que corresponden a polígonos como se explica en el Capítulo II. El resultado de la generación de cartografía por Deep Learning se encuentra en el Capítulo IV.

### **Exactitud espacial de la cartografía de los procesos de digitalización y Deep Learning**

En esta etapa se va hacer una evaluación de la cartografía generada por digitalización y Deep Learning, analizando los estadísticos media, desviación estándar, el máximo y mínimo, y de igual manera, se va a emplear la política de control del Instituto Geográfico Militar (IGM) y la norma NSSDA, aplicando 20 puntos de validación, distribuidos en el área mapeada, de forma aleatoria.

### **Evaluación exactitud posicional planimétrica de cartografía digitalizada y por Deep Learning**

Para la evaluación de la exactitud posicional de las cartografías se utiliza el mismo criterio de la evaluación de exactitud posicional planimétrica de ortoimágenes.

Se aplica la norma National Standard for Spatial Data Accuracy (NSSDA) haciendo uso de las ecuaciones 1, 2, 3 y 5, para lograr alcanzar la exactitud posicional planimétrica, y de la misma manera se aplica la norma IGM haciendo uso de la ecuación 9 detalladas en el Capítulo II.

El elenco de coordenadas comparativas descrito en el Capítulo IV, será insumo para calcular la estadística normativa.

Aplicando la norma NSSDA, se calcula lo siguiente:

$$RMSE_x = \sqrt{\frac{6.306}{20}}$$

$$RMSE_x = 0.562 \text{ m}$$

$$RMSE_y = \sqrt{\frac{7.648}{20}}$$

$$RMSE_y = 0.618 \text{ m}$$

$$RMSE_r = \sqrt{\frac{6.306 + 7.648}{20}}$$

$$RMSE_r = 0.835 \text{ m}$$

Caso 2: si  $RMSE_x \neq RMSE_y$  se aplica la ecuación (5):

$$Exactitud \ r = 2.4477 \times 0.5 \times (0.562 + 0.681)$$

$$Exactitud \ r = 1.444 \text{ m}$$

Aplicando la norma IGM, se calcula lo siguiente:

Caso 2: cuando  $RMSE_x \neq RMSE_y$ , la exactitud posicional se calculará de la siguiente manera:

$$Exactitud \ r = 2.1460 \times 0.5 \times (0.562 + 0.681)$$

$$Exactitud \ r = 1.266 \text{ m}$$

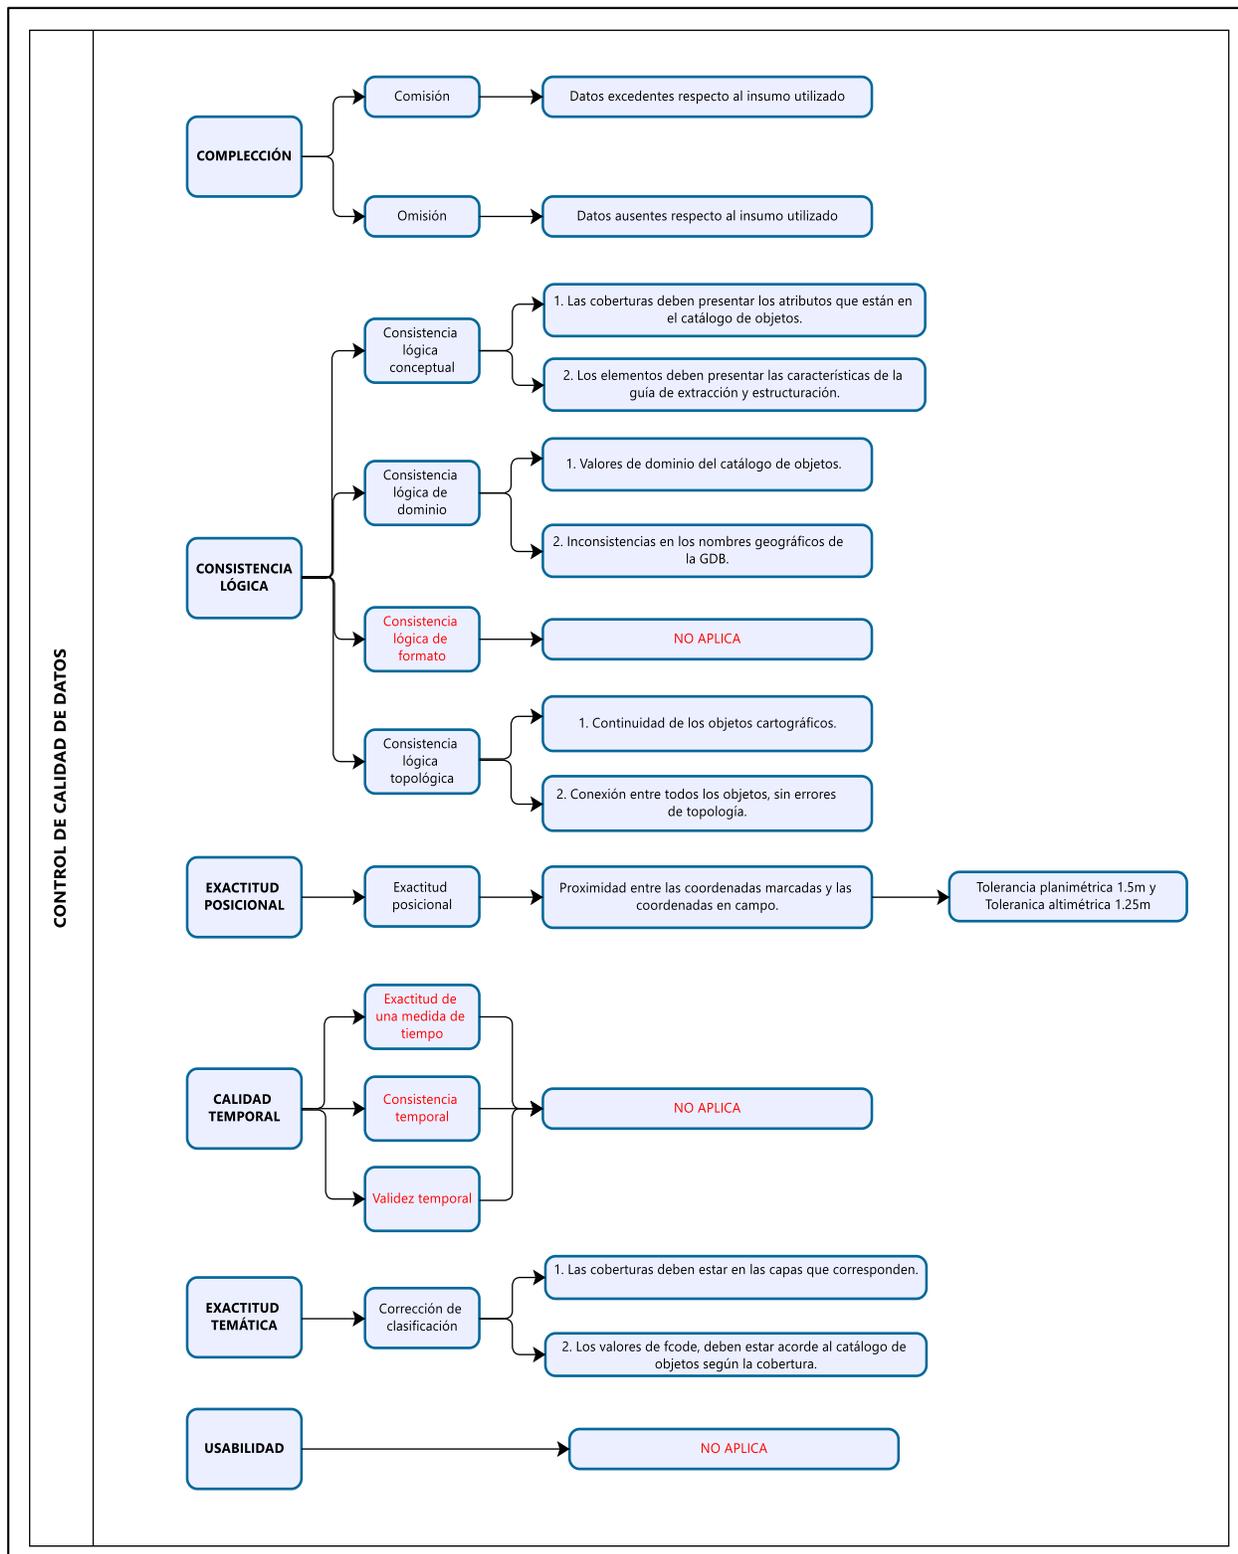
Los resultados obtenidos de la evaluación planimétrica de las cartografías se detallan en el Capítulo IV.

### **Control de calidad de datos en base a la norma ISO 19157**

En base a la norma ISO 19157 se realiza el control de calidad de datos, aplicado para las dos cartografías generadas; en este proceso se emplea el método de investigación comparativo. En la Figura 46, se muestra un esquema detallado de los elementos que se pueden aplicar para elaborar el control de calidad de datos.

Figura 46.

Norma ISO 19157, elementos aplicables

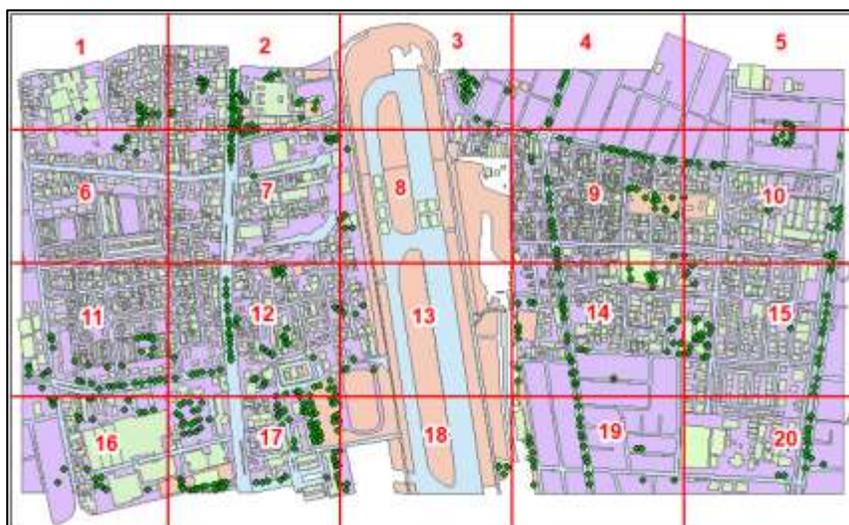


### ***Control de Compleción***

Se analiza la presencia (comisiones) o ausencia (omisiones) de datos, para ello se realiza una grilla de 200ha de área en la zona de estudio; en cada uno de los cuadros generados por la grilla se observa que no existan omisiones o comisiones, si aparecen se procede a corregir hasta que no aparezcan errores. Como resultado de este proceso se obtiene una tabla que se encuentra en el Capítulo IV “Resultados de Control de Compleción”. En la Figura 47, se muestra la grilla para verificación de omisiones y comisiones.

**Figura 47.**

*Distribución de grilla para control de completión*



### ***Control de Consistencia lógica***

Dentro de la consistencia lógica se encuentran: consistencia lógica conceptual, consistencia lógica de dominio y la consistencia lógica topológica. Con respecto a la consistencia lógica conceptual dada en el catálogo de objetos a escala 1:5000, se revisa detalladamente que las feature class se encuentren acorde a lo mencionado en el catálogo de objetos. La consistencia de dominio asegura que los mismos estén subidos en la GDB final. La

consistencia topológica realiza la topología de líneas y polígonos para obtener una cartografía depurada, lista para ser catalogada. En la Figura 48, se muestran los campos presentes en los feature class, así como los dominios subidos en la capa de edificaciones.

**Figura 48.**

*Consistencia de dominio*

The figure shows a screenshot of a GIS software interface. On the left, a 'Table' window displays the structure of the 'edificio\_a' feature class. It has four columns: 'nam', 'acc', 'afc', and 'cef'. The 'acc' column is currently selected, and a dropdown menu is open showing the following domain values: '<Null>', '-1.- Información', '1.- Exacta', '2.- Aproximada', '3.- Dudosa', '7.- Precisa', and '998.- No aplica'. On the right, a legend for the 'Edificio' feature class lists the following fields and their descriptions:

Edificio	nam	Nombre
	acc	Código de Categoría de Precisión Horizontal
	afc	Código del Tipo de Instalación Agrícola
	cef	Código del Tipo de Instalación Cultural
	cfc	Código del Tipo de Instalación Comercial
	cit	Código del Tipo de Instalación Comercial
	cos	Código del Tipo de Instalaciones de Comunicación

acc	Código de Categoría de Precisión Horizontal	
-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.

### Control de Exactitud posicional según la estadística normativa

Está descrito en los apartados de: Evaluación exactitud posicional planimétrica con estadística normativa de cartografía digitalizada y en Evaluación exactitud posicional planimétrica con estadística normativa de las ortoimágenes.

Se obtienen tablas resumidas de la exactitud posicional en base a las normas NSSDA e IGM para las ortoimágenes y la cartografía digitalizada, en las que se detallan estadísticos como: media, desviación estándar, máximo y mínimo,  $RMSE_x$ ,  $RMSE_y$ ,  $RMSE_z$ ,  $RMSE_r$ , Exactitud

R (95% de confianza), Exactitud V (95% de confianza), Exactitud R (90% de confianza). Los resultados se encuentran en el Capítulo IV, en la sección de control de calidad de datos aplicando la Norma ISO 19157.

## Capítulo IV

### Resultados

En este capítulo se detallan los resultados obtenidos de la metodología, así mismo, en donde sea necesario, se incluirá el análisis correspondiente.

#### Resultados del control terrestre

##### *Resultados de la toma de puntos de apoyo (GCP)*

En las Tablas 8, 9 y 10 se detallan los elencos de coordenadas tomados con el equipo GNSS Trimble R8, doble frecuencia, por el método NTRIP, Sistema de Referencia WGS84, coordenadas proyectadas Universal Transversa de Mercator (UTM), zona 17S, que servirán para ortorrectificar cada par estéreo de los años 2014, 2016 y 2018.

**Tabla 8.**

*Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2014*

Nombre	Este (m)	Norte (m)	Altura	Precisión	Precisión
			elipsoidal (m)	Horizontal (m)	Vertical (m)
NTS01	776905.381	9987816.231	2921.002	0.009	0.019
NTS02	778702.301	9987814.552	2789.398	0.013	0.025
NTS03	780010.881	9987774.139	2823.061	0.021	0.043
NTS04	782107.544	9987738.358	2776.382	0.017	0.032
NTS05	784324.330	9987695.735	2673.154	0.013	0.023
NTS06	786427.258	9987781.035	2663.375	0.017	0.034
NTS07	777159.705	9985919.758	3097.645	0.017	0.028

NTS08	778730.428	9986370.742	2832.338	0.03	0.059
NTS09	781084.983	9986855.270	2983.391	0.017	0.039
NTS10	783105.438	9987016.612	2716.408	0.017	0.03
NTS11	780898.009	9984815.343	2873.068	0.037	0.064
NTS12	783189.976	9985074.825	2877.251	0.022	0.038
NTS13	784840.349	9985437.042	2633.466	0.009	0.018
NTS14	786458.654	9985813.983	2594.048	0.014	0.028
NTS15	779370.050	9983799.923	2835.850	0.013	0.031
NTS16	782056.121	9984312.729	2920.167	0.022	0.041
NTS17	783532.004	9983947.149	2818.568	0.014	0.021
NTS18	785130.451	9984831.731	2634.086	0.012	0.023
NTS19	777723.214	9983019.018	3011.030	0.014	0.022
NTS20	779164.270	9983100.773	2837.075	0.012	0.032
NTS21	785367.414	9983308.945	2606.185	0.02	0.032
NTS22	786516.415	9982748.797	2511.137	0.012	0.017
NTS23	779031.979	9981716.003	2876.020	0.022	0.031
NTS24	777821.790	9982370.828	3019.976	0.02	0.052
NTS25	781117.089	9982684.843	2824.311	0.019	0.03
NTS26	782694.807	9982428.724	2908.471	0.015	0.033
NTS27	780766.257	9981504.404	2806.377	0.014	0.035
NTS28	781950.018	9981760.769	2855.934	0.019	0.038
NTS29	784113.058	9981702.597	2715.699	0.015	0.023
NTS30	785678.789	9981491.066	2511.955	0.014	0.022
NTS31	776923.663	9980133.676	3073.589	0.027	0.05
NTS32	777159.504	9979426.313	2985.199	0.029	0.056

NTS33	780211.371	9980253.748	2806.206	0.008	0.017
NTS34	781819.789	9980074.031	2948.934	0.02	0.034
NTS35	784241.405	9979863.020	2551.950	0.04	0.053
NTS36	785662.097	9979956.476	2445.357	0.015	0.024
NTS37	786559.494	9979021.857	2387.945	0.022	0.039
NTS38	777066.258	9978266.700	2918.167	0.02	0.035
NTS39	779150.284	9978434.500	2810.388	0.026	0.047
NTS40	780381.080	9978887.398	2794.360	0.008	0.017
NTS41	784234.347	9978173.683	2507.655	0.035	0.044
NTS42	786411.547	9978214.366	2365.783	0.019	0.026

**Tabla 9.**

*Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2016*

Nombre	Este (m)	Norte (m)	Altura	Precisión	Precisión
			elipsoidal (m)	Horizontal (m)	Vertical (m)
NTE01	777139.284	9986131.847	3069.154	0.018	0.036
NTE02	778043.847	9986139.861	2886.956	0.033	0.048
NTE03	778730.411	9986370.754	2832.280	0.03	0.059
NTE04	781084.983	9986855.270	2983.391	0.017	0.039
NTE05	777442.059	9985118.785	2955.577	0.012	0.02
NTE06	778622.287	9985489.245	2849.189	0.038	0.058
NTE07	779880.825	9986063.677	2865.244	0.03	0.058
NTE08	780983.066	9986275.753	2946.330	0.026	0.039

NTE09	777448.206	9984490.336	2978.989	0.027	0.038
NTE10	777845.308	9984185.127	2939.183	0.014	0.025
NTE11	779003.834	9984956.815	2845.089	0.025	0.04
NTE12	780097.611	9985525.211	2870.821	0.029	0.056
NTE13	782011.781	9986127.419	2901.783	0.037	0.067
NTE14	778550.789	9984269.168	2867.232	0.032	0.049
NTE15	780084.674	9984828.570	2850.777	0.021	0.034
NTE16	780540.161	9985004.512	2868.534	0.022	0.037
NTE17	780897.992	9984815.355	2873.010	0.037	0.064
NTE18	781841.760	9985477.431	2943.595	0.012	0.023
NTE19	778355.478	9983856.814	2898.847	0.042	0.062
NTE20	777723.197	9983019.030	3010.972	0.014	0.022
NTE21	778630.227	9983282.309	2884.648	0.021	0.026
NTE22	780424.966	9983771.293	2829.028	0.022	0.032
NTE23	779370.033	9983799.935	2835.792	0.013	0.031
NTE24	780667.058	9984092.727	2838.860	0.035	0.056
NTE25	780887.974	9983894.085	2848.899	0.03	0.047
NTE26	781376.723	9984251.012	2878.831	0.029	0.054
NTE27	782063.941	9984313.902	2920.282	0.018	0.036
NTE28	778411.151	9982885.034	2905.922	0.009	0.02
NTE29	779164.253	9983100.785	2837.017	0.012	0.032
NTE30	779111.555	9982456.891	2844.846	0.017	0.034
NTE31	779661.767	9982794.852	2823.402	0.038	0.055
NTE32	780707.891	9983118.611	2823.855	0.014	0.039
NTE33	781688.405	9983091.145	2828.874	0.011	0.027

NTE34	778431.777	9981924.856	2927.675	0.015	0.034
NTE35	778844.181	9981595.422	2887.372	0.029	0.055
NTE36	779031.962	9981716.015	2875.962	0.022	0.031
NTE37	779861.699	9982004.605	2811.480	0.01	0.024
NTE38	780764.975	9982462.002	2824.058	0.014	0.043
NTE39	781138.686	9982532.916	2831.627	0.012	0.021
NTE40	781614.822	9982085.642	2842.312	0.027	0.044
NTE41	782369.002	9982333.989	2889.921	0.03	0.053
NTE42	782575.577	9982787.244	2896.882	0.016	0.042

**Tabla 10.**

*Resultados del elenco de coordenadas de puntos de apoyo (GCP) del año 2018*

Nombre	Este (m)	Norte (m)	Altura	Precisión	Precisión
			elipsoidal (m)	Horizontal (m)	Vertical (m)
NTM01	777137.796	9986131.902	3068.216	0.018	0.036
NTM02	777159.705	9985919.76	3097.645	0.017	0.028
NTM03	778730.428	9986370.74	2832.338	0.030	0.059
NTM04	780983.083	9986275.74	2946.388	0.026	0.039
NTM05	781675.119	9986735	2942.953	0.044	0.067
NTM06	777442.076	9985118.77	2955.635	0.012	0.020
NTM07	782224.465	9985118.773	2915.232	0.031	0.044
NTM08	780097.628	9985525.2	2870.879	0.029	0.056
NTM09	782011.798	9986127.407	2901.841	0.037	0.067

NTM10	777586.514	9984854.530	2941.688	0.013	0.021
NTM11	779003.851	9984956.8	2845.147	0.025	0.040
NTM12	777448.223	9984490.32	2979.047	0.027	0.038
NTM13	778537.791	9984560.72	2865.657	0.019	0.025
NTM14	780084.691	9984828.56	2850.835	0.021	0.034
NTM15	780540.178	9985004.500	2868.592	0.022	0.037
NTM16	780898.009	9984815.34	2873.068	0.037	0.064
NTM17	777723.214	9983019.02	3011.030	0.014	0.022
NTM18	777843.649	9983088.2	2995.189	0.020	0.033
NTM19	778630.244	9983282.3	2884.706	0.021	0.026
NTM20	778874.611	9983666.51	2859.045	0.022	0.031
NTM21	779370.050	9983799.923	2835.850	0.013	0.031
NTM22	780424.983	9983771.28	2829.086	0.022	0.032
NTM23	780667.075	9984092.72	2838.918	0.035	0.056
NTM24	780887.991	9983894.07	2848.957	0.030	0.047
NTM25	781285.980	9984533.98	2883.268	0.014	0.029
NTM26	781912.708	9984294.611	2907.488	0.031	0.062
NTM27	778565.157	9984271.267	2867.329	0.014	0.030
NTM28	781375.656	9984219.786	2878.869	0.022	0.049
NTM29	782197.008	9984269.61	2927.318	0.011	0.021
NTM30	778599.387	9982673.92	2887.578	0.019	0.028
NTM31	779160.159	9983096.75	2837.153	0.025	0.038
NTM32	779661.784	9982794.840	2823.460	0.038	0.055
NTM33	781755.072	9983253.72	2837.383	0.012	0.024
NTM34	778431.794	9981924.844	2927.733	0.015	0.034

NTM35	780764.992	9982461.990	2824.116	0.014	0.043
NTM36	781138.703	9982532.9	2831.685	0.012	0.021
NTM37	782551.599	9982894.36	2901.920	0.025	0.045
NTM38	778844.198	9981595.410	2887.43	0.029	0.055
NTM39	779031.979	9981716	2876.020	0.022	0.031
NTM40	779861.716	9982004.593	2811.538	0.010	0.024
NTM41	781614.839	9982085.630	2842.370	0.027	0.044
NTM42	782369.019	9982333.98	2889.979	0.030	0.053

### ***Resultados de la evaluación de la precisión de puntos de apoyo (GCP)***

A continuación en la Tabla 11, se presentan las precisiones de los puntos de apoyo (GCP) tomados en campo para los años 2014, 2016 y 2018.

**Tabla 11.**

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

<b>Año</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Dist. Max (m)</b>	<b>Dist. Min (m)</b>
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

Una vez obtenidos los estadísticos, se observa que la media de las precisiones no sobrepasa los 0.5 m, como se especifica en la normativa IGM.

### ***Resultados de puntos de validación de exactitud posicional***

En las Tablas 12, 13 y 14 se detallan los elencos de coordenadas tomados con el equipo GNSS Trimble R8, doble frecuencia, por el método NTRIP, Sistema de Referencia

WGS84, coordenadas proyectadas Universal Transversa de Mercator (UTM), zona 17S, mismas que servirán para evaluar la exactitud posicional de ortoimágenes.

**Tabla 12.**

*Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2014*

<b>Nombre</b>	<b>Este (m)</b>	<b>Norte (m)</b>	<b>Altura elipsoidal (m)</b>	<b>Precisión Horizontal (m)</b>	<b>Precisión Vertical (m)</b>
NTVS01	777478.535	9987620.183	2879.676	0.028	0.039
NTVS02	777522.786	9986160.085	2980.051	0.021	0.037
NTVS03	779200.492	9986698.539	2809.139	0.019	0.036
NTVS04	781083.761	9986846.827	2983.445	0.042	0.069
NTVS05	784837.852	9987176.209	2661.226	0.012	0.022
NTVS06	778662.472	9985502.652	2847.31	0.031	0.044
NTVS07	780097.596	9984534.245	2839.397	0.016	0.029
NTVS08	784607.937	9985445.323	2638.071	0.011	0.018
NTVS09	784868.515	9984731.822	2641.276	0.009	0.024
NTVS10	784852.732	9983542.892	2632.926	0.023	0.037
NTVS11	785584.891	9982712.510	2595.035	0.022	0.027
NTVS12	778373.109	9981939.080	2932.228	0.018	0.028
NTVS13	776818.127	9978907.182	2994.882	0.012	0.02
NTVS14	777903.889	9978283.997	2861.055	0.032	0.053
NTVS15	779052.783	9979216.692	2833.588	0.017	0.03
NTVS16	779919.644	9980113.308	2809.06	0.008	0.018

NTVS17	781805.670	9980108.118	2945.661	0.017	0.028
NTVS18	784238.698	9980569.672	2611.877	0.013	0.022
NTVS19	783865.046	9978180.992	2502.192	0.025	0.033
NTVS20	785544.984	9978329.025	2422.634	0.025	0.043

**Tabla 13.**

*Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2016*

Nombre	Este (m)	Norte (m)	Altura	Precisión	Precisión
			elipsoidal (m)	Horizontal (m)	Vertical (m)
NTVE01	777522.786	9986160.085	2980.051	0.021	0.037
NTVE02	778188.401	9985856.394	2872.56	0.022	0.032
NTVE03	779395.611	9986305.498	2821.693	0.009	0.017
NTVE04	780192.677	9986693.094	2876.978	0.012	0.026
NTVE05	781083.761	9986846.827	2983.445	0.042	0.069
NTVE06	778662.472	9985502.652	2847.31	0.031	0.044
NTVE07	779856.584	9986073.042	2865.304	0.04	0.071
NTVE08	780538.796	9985492.743	2893.631	0.031	0.056
NTVE09	781029.542	9986007.639	2926.441	0.021	0.047
NTVE10	781847.193	9985470.905	2943.701	0.026	0.052
NTVE11	778803.495	9984446.439	2851.403	0.012	0.024
NTVE12	778917.666	9983993.663	2849.198	0.012	0.021
NTVE13	780097.596	9984534.245	2839.397	0.016	0.029

NTVE14	781342.928	9984144.808	2870.06	0.02	0.029
NTVE15	780816.487	9983392.497	2827.495	0.011	0.025
NTVE16	780199.727	9982977.201	2820.424	0.016	0.031
NTVE17	777821.790	9982370.828	3019.976	0.02	0.052
NTVE18	778380.314	9981940.735	2932.334	0.016	0.024
NTVE19	781114.791	9982687.089	2824.201	0.022	0.034
NTVE20	782327.010	9982199.997	2885.898	0.016	0.025

**Tabla 14.**

*Resultados del elenco de coordenadas de puntos de validación de ortoimágenes del año 2018*

Nombre	Este (m)	Norte (m)	Altura	Precisión	Precisión
			elipsoidal (m)	Horizontal (m)	Vertical (m)
NTVM01	782327.010	9982199.997	2885.898	0.016	0.025
NTVM02	779395.611	9986305.498	2821.693	0.009	0.017
NTVM03	781084.983	9986855.270	2983.391	0.017	0.039
NTVM04	780535.402	9985492.867	2893.39	0.031	0.050
NTVM05	780096.523	9984540.895	2839.367	0.028	0.036
NTVM06	781342.928	9984144.808	2870.06	0.020	0.029
NTVM07	780810.816	9983394.994	2827.436	0.013	0.029
NTVM08	779107.672	9982456.696	2845.145	0.019	0.039
NTVM09	778622.287	9985489.245	2849.189	0.038	0.058
NTVM10	778189.432	9985847.985	2872.574	0.030	0.044

NTVM11	778373.109	9981939.080	2932.228	0.018	0.028
NTVM12	778411.151	9982885.034	2905.922	0.009	0.020
NTVM13	778146.262	9983362.919	2936.219	0.019	0.044
NTVM14	778917.666	9983993.663	2849.198	0.012	0.021
NTVM15	778804.886	9984437.845	2851.320	0.019	0.027
NTVM16	777520.394	9986153.339	2979.992	0.028	0.046
NTVM17	780192.677	9986693.094	2876.978	0.012	0.026
NTVM18	781029.542	9986007.639	2926.441	0.021	0.047
NTVM19	780199.727	9982977.201	2820.424	0.016	0.031
NTVM20	781122.931	9982691.220	2824.401	0.026	0.049

***Resultados de la evaluación de la precisión de puntos de evaluación de la exactitud posicional***

En la Tabla 15, se presentan las precisiones de los puntos de validación de exactitud posicional tomados en campo para los años 2014, 2016 y 2018.

**Tabla 15.**

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

<b>Año</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Dist. Max (m)</b>	<b>Dist. Min (m)</b>
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

Una vez analizados los estadísticos se observa que las precisiones no superan los 0.5 m, como se especifica en la normativa IGM.

## Resultados de la generación de ortoimágenes

### Resultados de la Aerotriangulación

A continuación en la Tabla 16 se detalla el error medio cuadrático (RMSE) de cada uno de los modelos con la cada cantidad de GCP con las que fueron procesadas, es decir, con 42 GCP, 30 GCP, 21 GCP, 9 GCP Y 7 GCP respectivamente.

**Tabla 16.**

*Resultado de la Aerotriangulación para cada modelo*

Año	Área Km <sup>2</sup>	# Puntos	RMSE	RMSE
			RPC (pixels)	Polynomial (pixels)
Ortoimágenes 2014	100 km <sup>2</sup>	42	0.495	-
		30	0.425	-
		21	0.335	-
		9	0.218	-
		7	0.188	-
Ortoimágenes 2016	25 km <sup>2</sup>	42	0.306	0.775
		30	0.253	0.470
		21	0.293	0.397

		9	0.184	0.722
		7	0.180	0.00026
		42	0.126	-
		30	0.120	-
Ortoimágenes 2018	25 km <sup>2</sup>	21	0.123	-
		9	0.126	-
		7	0.127	-

En la Tabla 16, se muestra el RMSE en unidades pixel por los dos modelos: modelo WorldView RPC que se evaluó con las ortoimágenes de los años 2014, 2016 y 2018; mientras que por el modelo Polynomial Based in Pushbroom se evaluó solo con la ortoimagen del año 2016, en los que se puede observar que no sobrepasan el pixel.

### ***Resultados del reporte de Aerotriangulación***

A continuación en la Figura 49 se presenta un ejemplo del reporte generado después del proceso de Aerotriangulación con el modelo RPC del año 2014, con 42 puntos. Cada uno de los procesos que se llevan a cabo por los dos métodos tienen su respectivo reporte, donde se puede encontrar: el error medio cuadrático ( $RMSE_x$ ,  $RMSE_y$ ), la diferencia entre los puntos de control y los pinchados en las imágenes, los residuales de los puntos de la imagen con respecto a los puntos de control, estos residuales se encuentran en unidades de metro según el reporte de Aerotriangulación.

Figura 49.

## Reporte de Aerotriangulación

0.5183 0.6214

The image residuals of intersected GCP

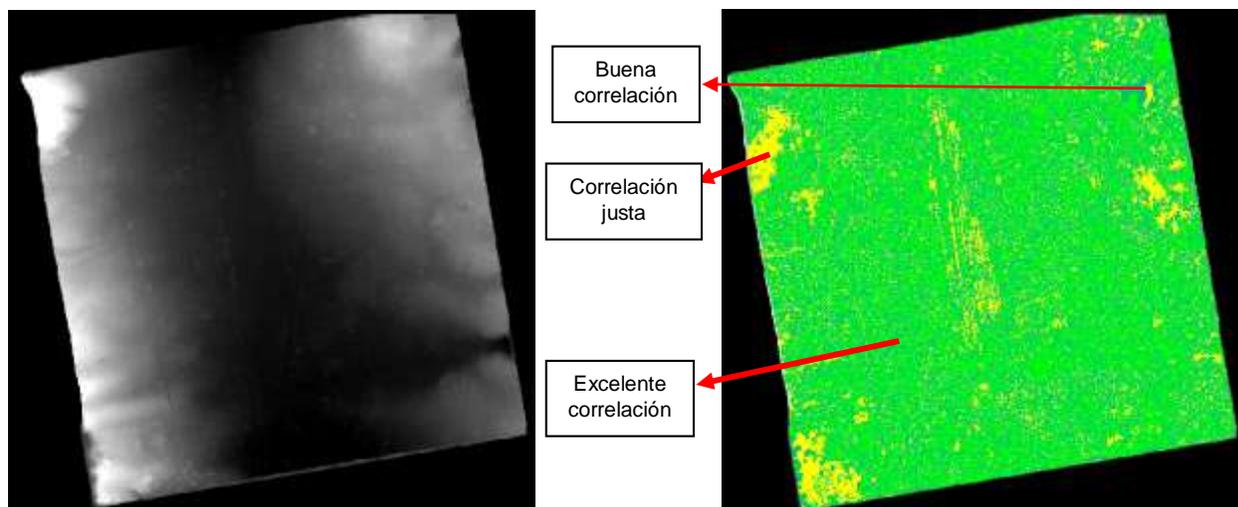
Point	Image	Vx	Vy
1	1	-0.079	-0.039
1	2	0.050	-0.005
2	1	0.135	-0.017
2	2	-0.222	-0.067
3	1	0.024	-0.062
3	2	-0.157	-0.059
4	1	-0.132	-0.125
4	2	-0.073	-0.050
5	1	-0.387	-0.209
5	2	0.109	-0.021
6	1	-0.350	-0.227
6	2	0.007	-0.044
7	1	-0.314	-0.198
7	2	0.158	-0.079
8	1	-0.349	-0.197
8	2	0.172	-0.059
10	1	-0.001	-0.150
10	2	-0.280	-0.132
11	1	-0.222	-0.287
11	2	-0.122	-0.204
12	1	0.071	-0.246
12	2	-0.475	-0.270

### Resultados de la generación MDS por correlación con el modelo RPC y el modelo Polynomial Based in Pushbroom

Se generaron en total 20 Modelos Digitales de Superficie (MDS), 15 MDS aplicando el modelo de Aerotriangulación RPC y 5 por el modelo Polynomial Based in Pushbroom. A continuación en la Figura 50 se ejemplifica un modelo del año 2016 con 42 GCP, donde se puede observar el MDS con su respectivo informe de calidad, el cual indica que, en las zonas de color verde claro, existe una excelente correlación, en las de color verde más oscuro una buena correlación y en las de color amarillo una correlación justa.

**Figura 50.**

*MDS e informe de calidad*

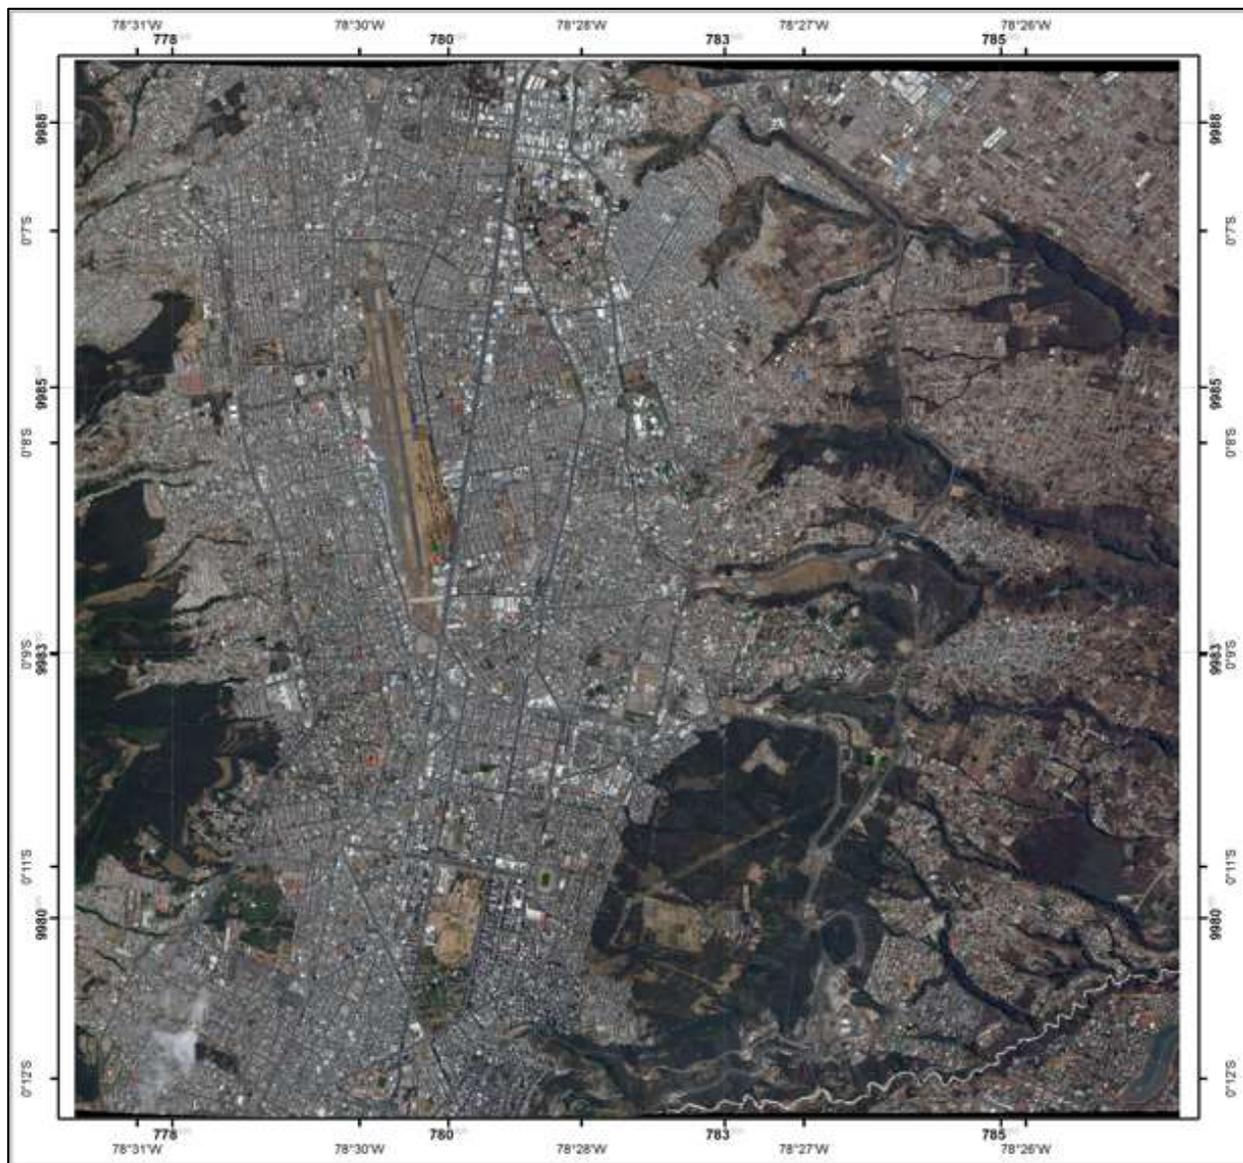


### ***Resultados de ortoimágenes por el modelo de Aerotriangulación RPC***

Se obtuvieron un total de 15 ortoimágenes por este método, debido a que, se procesaron los pares estéreo de los años 2014, 2016 y 2018 en el software ERDAS 2014 con 42 GCP, 30 GCP, 21 GCP, 9 GCP Y 7 GCP respectivamente. Se puede observar un ejemplo en la Figura 51.

**Figura 51.**

*Ortoimagen con 42 GCP del año 2014*

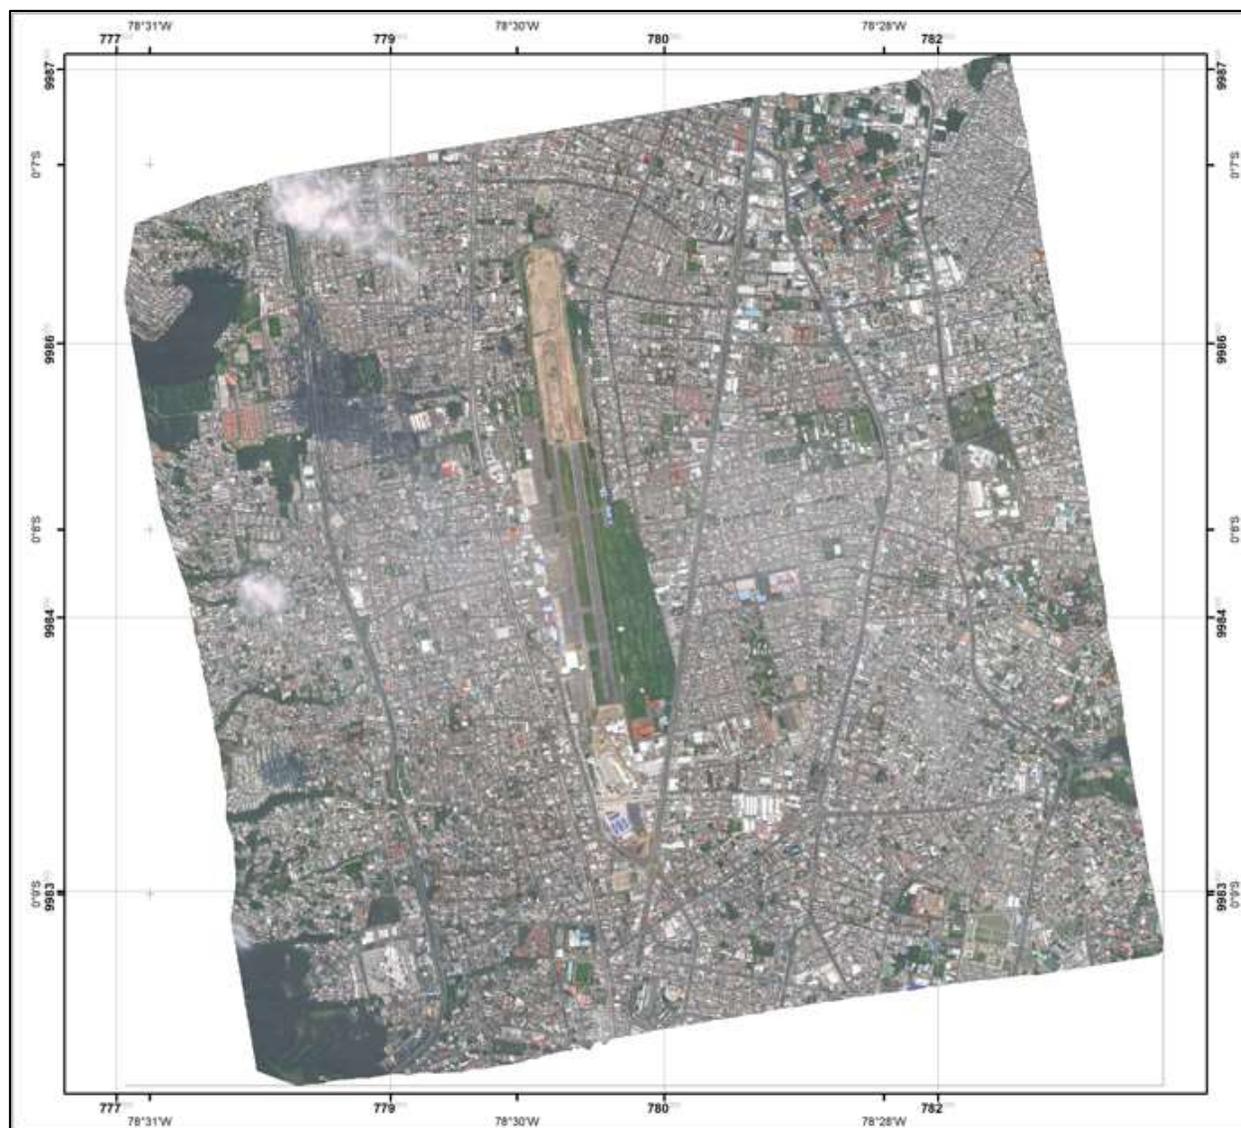


***Resultados de ortoimágenes por el método de Aerotriangulación Directa***

Se obtuvieron un total de 5 ortoimágenes por el método de Aerotriangulación Directa, en el par estéreo del año 2016 en el software ERDAS 2014, con 42 GCP, 30 GCP, 21 GCP, 9 GCP Y 7 GCP respectivamente. Se puede observar un ejemplo en la Figura 52.

**Figura 52.**

*Ortoimagen con 42 GCP del año 2018*



A continuación en la Tabla 17, se muestran los valores de media, desviación estándar, máximo y mínimo, de las distancias entre los puntos de referencia y sus homólogos en las ortofotografías del año 2016.

**Tabla 17.**

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

<b>Año</b>	<b>Área Km<sup>2</sup></b>	<b># Puntos</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Dist. Máx (m)</b>	<b>Dist. Min (m)</b>
Ortoimágenes 2016	25 km <sup>2</sup>	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

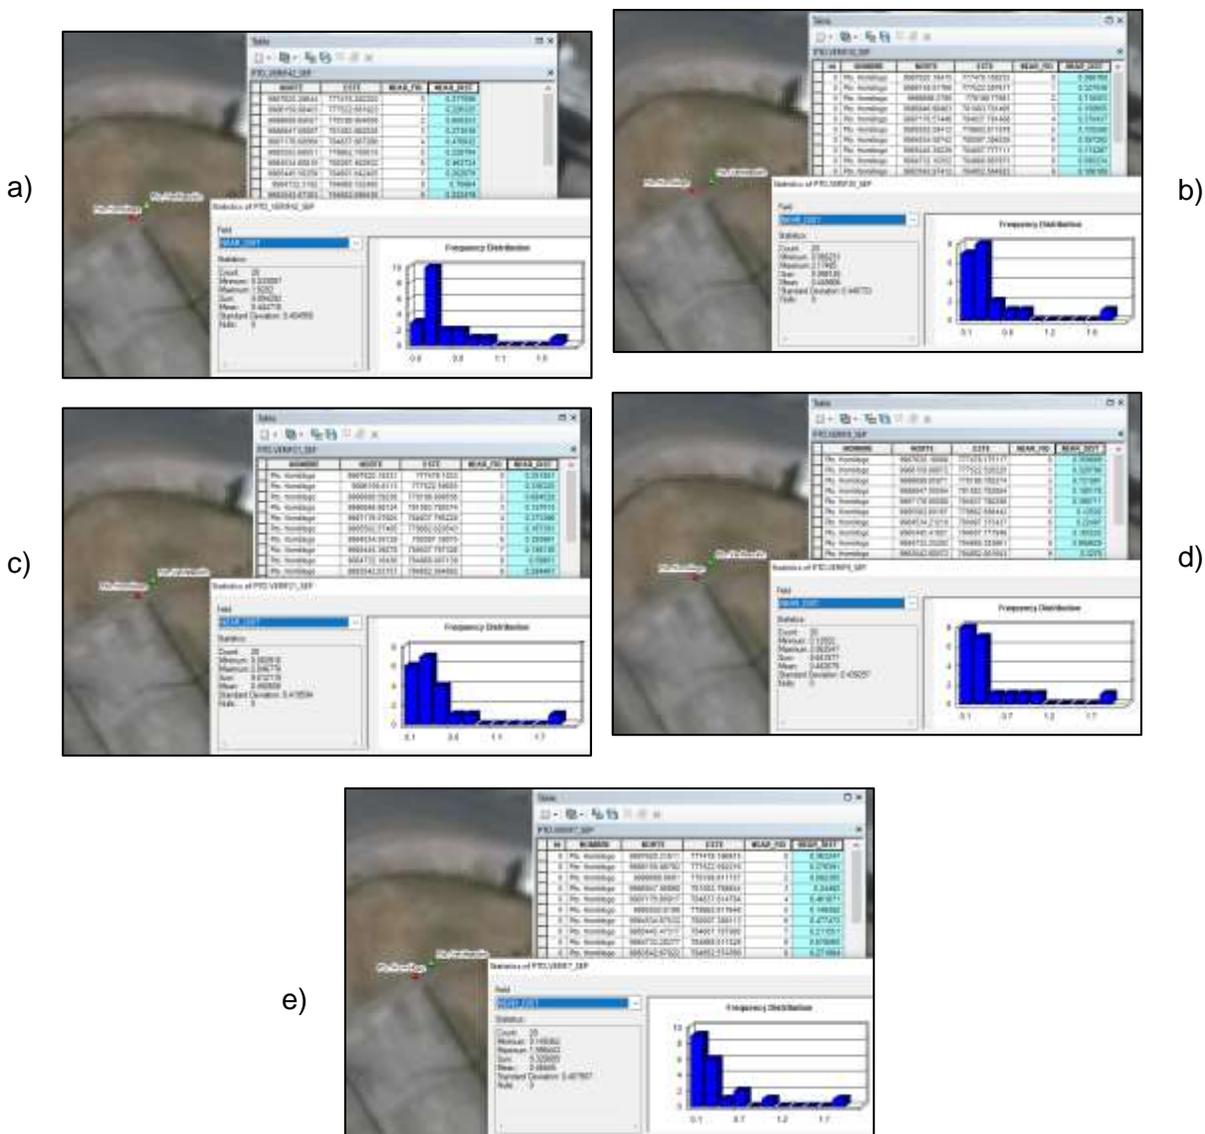
Una vez generadas las ortoimágenes por el modelo Polynomial based in Pushbroom, se calcularon las distancias entre los puntos de referencia y sus homólogos en la imagen y se puede observar en la Tabla 15 que no cumplen con la tolerancia de exactitud planimétrica descrita en la norma IGM que es de 1.5m, ya que sobrepasan este valor, por lo que no se procedió a calcular los estadísticos necesarios para validar las ortoimágenes.

### **Resultados de la exactitud espacial por estadística clásica de los productos derivados del ajuste**

Como se menciona en la metodología, en la validación de las ortoimágenes se generan archivos en formato shapefile que sirven para calcular el desplazamiento que existe entre el punto de referencia y su homólogo en cada ortoimagen. En la Figura 53, correspondiente al año 2014, se observa la distancia existente entre los puntos; así como también, los 20 puntos de validación con su respectivo estadístico.

Figura 53.

Desplazamientos de los puntos de referencia y sus homólogos en la ortoimagen 2014



Nota. Imágenes estadísticas 2014: a) 42 puntos, b) 30 puntos, c) 21 puntos, d) 9 puntos, e) 7 puntos

En las Tablas 18, 19, 20, 21 y 22, se muestran los elencos de coordenadas comparativas, usadas como partida para calcular la estadística clásica en las ortoimágenes del año 2014.

**Tabla 18.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con  
42 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9987620.183	777478.535	9987620.296	777478.282
2	9986160.085	777522.786	9986159.884	777522.682
3	9986698.539	779200.492	9986698.695	779199.904
4	9986846.827	781083.761	9986847.081	781083.863
5	9987176.209	784837.852	9987176.686	784837.867
6	9985502.652	778662.472	9985502.681	778662.700
7	9984534.245	780097.596	9984534.688	780097.463
8	9985445.323	784607.937	9985445.503	784607.842
9	9984731.822	784868.515	9984732.319	784869.102
10	9983542.892	784852.732	9983542.674	784852.689
11	9982712.51	785584.891	9982712.311	785584.690
12	9981939.08	778373.109	9981939.098	778373.080
13	9978907.182	776818.127	9978905.942	776816.661
14	9978283.997	777903.889	9978283.491	777903.063
15	9979216.692	779052.783	9979216.707	779053.079
16	9980113.308	779919.644	9980113.511	779919.490
17	9980108.118	781805.67	9980107.898	781805.511
18	9980569.672	784238.698	9980569.499	784238.706
19	9978180.992	783865.046	9978180.720	783865.083

20            9978329.025    785544.984    9978328.699    785545.567

---

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 19.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 30 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9987620.18	777478.535	9987620.184	777478.168
2	9986160.09	777522.786	9986159.818	777522.598
3	9986698.54	779200.492	9986698.580	779199.777
4	9986846.83	781083.761	9986846.985	781083.781
5	9987176.21	784837.852	9987176.574	784837.791
6	9985502.65	778662.472	9985502.584	778662.612
7	9984534.25	780097.596	9984534.587	780097.395
8	9985445.32	784607.937	9985445.392	784607.777
9	9984731.82	784868.515	9984732.184	784868.988
10	9983542.89	784852.732	9983542.974	784852.565
11	9982712.51	785584.891	9982712.200	785584.583
12	9981939.08	778373.109	9981939.003	778372.979
13	9978907.18	776818.127	9978906.197	776816.188
14	9978284	777903.889	9978283.809	777902.980

15	9979216.69	779052.783	9979217.000	779052.965
16	9980113.31	779919.644	9980113.794	779919.402
17	9980108.12	781805.67	9980107.798	781805.777
18	9980569.67	784238.698	9980569.803	784238.583
19	9978180.99	783865.046	9978180.988	783864.980
20	9978329.03	785544.984	9978329.031	785545.365

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 20.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 21 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9987620.18	777478.535	9987620.193	777478.183
2	9986160.09	777522.786	9986159.811	777522.591
3	9986698.54	779200.492	9986698.592	779199.810
4	9986846.83	781083.761	9986846.981	781083.790
5	9987176.21	784837.852	9987176.578	784837.795
6	9985502.65	778662.472	9985502.575	778662.621
7	9984534.25	780097.596	9984534.581	780097.391
8	9985445.32	784607.937	9985445.393	784607.797
9	9984731.82	784868.515	9984732.164	784869.007

10	9983542.89	784852.732	9983542.632	784852.595
11	9982712.51	785584.891	9982712.194	785584.589
12	9981939.08	778373.109	9981938.990	778373.006
13	9978907.18	776818.127	9978905.805	776816.613
14	9978284	777903.889	9978283.805	777902.991
15	9979216.69	779052.783	9979216.977	779052.998
16	9980113.31	779919.644	9980113.793	779919.409
17	9980108.12	781805.67	9980107.766	781805.399
18	9980569.67	784238.698	9980569.780	784238.618
19	9978180.99	783865.046	9978180.986	783864.985
20	9978329.03	785544.984	9978329.022	785545.407

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 21.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 9 GCP*

Puntos	Norte (obs)	Este (obs)	Norte (carto)	Este (carto)
	(m)	(m)	(m)	(m)
1	9987620.18	777478.535	9987620.18	777478.175
2	9986160.09	777522.786	9986159.89	777522.526
3	9986698.54	779200.492	9986698.66	779199.78

4	9986846.83	781083.761	9986847.01	781083.782
5	9987176.21	784837.852	9987176.6	784837.79
6	9985502.65	778662.472	9985502.6	778662.586
7	9984534.25	780097.596	9984534.21	780097.373
8	9985445.32	784607.937	9985445.42	784607.778
9	9984731.82	784868.515	9984732.25	784869.384
10	9983542.89	784852.732	9983542.6	784852.582
11	9982712.51	785584.891	9982712.23	785584.58
12	9981939.08	778373.109	9981939.02	778372.987
13	9978907.18	776818.127	9978905.89	776816.677
14	9978284	777903.889	9978283.43	777903.009
15	9979216.69	779052.783	9979216.62	779052.967
16	9980113.31	779919.644	9980113.41	779919.38
17	9980108.12	781805.67	9980107.8	781805.389
18	9980569.67	784238.698	9980569.42	784238.574
19	9978180.99	783865.046	9978180.6	783864.98
20	9978329.03	785544.984	9978328.62	785545.396

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 22.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2014 con 7*

*GCP*

<b>Puntos</b>	<b>Norte (obs)</b> <b>(m)</b>	<b>Este (obs)</b> <b>(m)</b>	<b>Norte (carto)</b> <b>(m)</b>	<b>Este (carto)</b> <b>(m)</b>
1	9987620.18	777478.535	9987620.316	777478.197
2	9986160.09	777522.786	9986159.888	777522.592
3	9986698.54	779200.492	9986698.668	779199.812
4	9986846.83	781083.761	9986847.069	781083.799
5	9987176.21	784837.852	9987176.669	784837.815
6	9985502.65	778662.472	9985502.619	778662.618
7	9984534.25	780097.596	9984534.675	780097.389
8	9985445.32	784607.937	9985445.473	784607.788
9	9984731.82	784868.515	9984732.284	784869.012
10	9983542.89	784852.732	9983542.670	784852.575
11	9982712.51	785584.891	9982712.276	785584.577
12	9981939.08	778373.109	9981939.058	778372.957
13	9978907.18	776818.127	9978905.881	776816.613
14	9978284	777903.889	9978283.457	777903.025
15	9979216.69	779052.783	9979216.656	779052.992
16	9980113.31	779919.644	9980113.470	779919.392
17	9980108.12	781805.67	9980107.850	781805.427
18	9980569.67	784238.698	9980569.487	784238.594
19	9978180.99	783865.046	9978180.651	783864.993

20      9978329.03      785544.984      9978328.724      785545.396

---

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

A continuación en la Tabla 23, se detallan los estadísticos media, desviación estándar, máximo y mínimo para las ortoimágenes del año 2014.

**Tabla 23.**

*Resultados de los estadísticos clásicos ortoimágenes del año 2014*

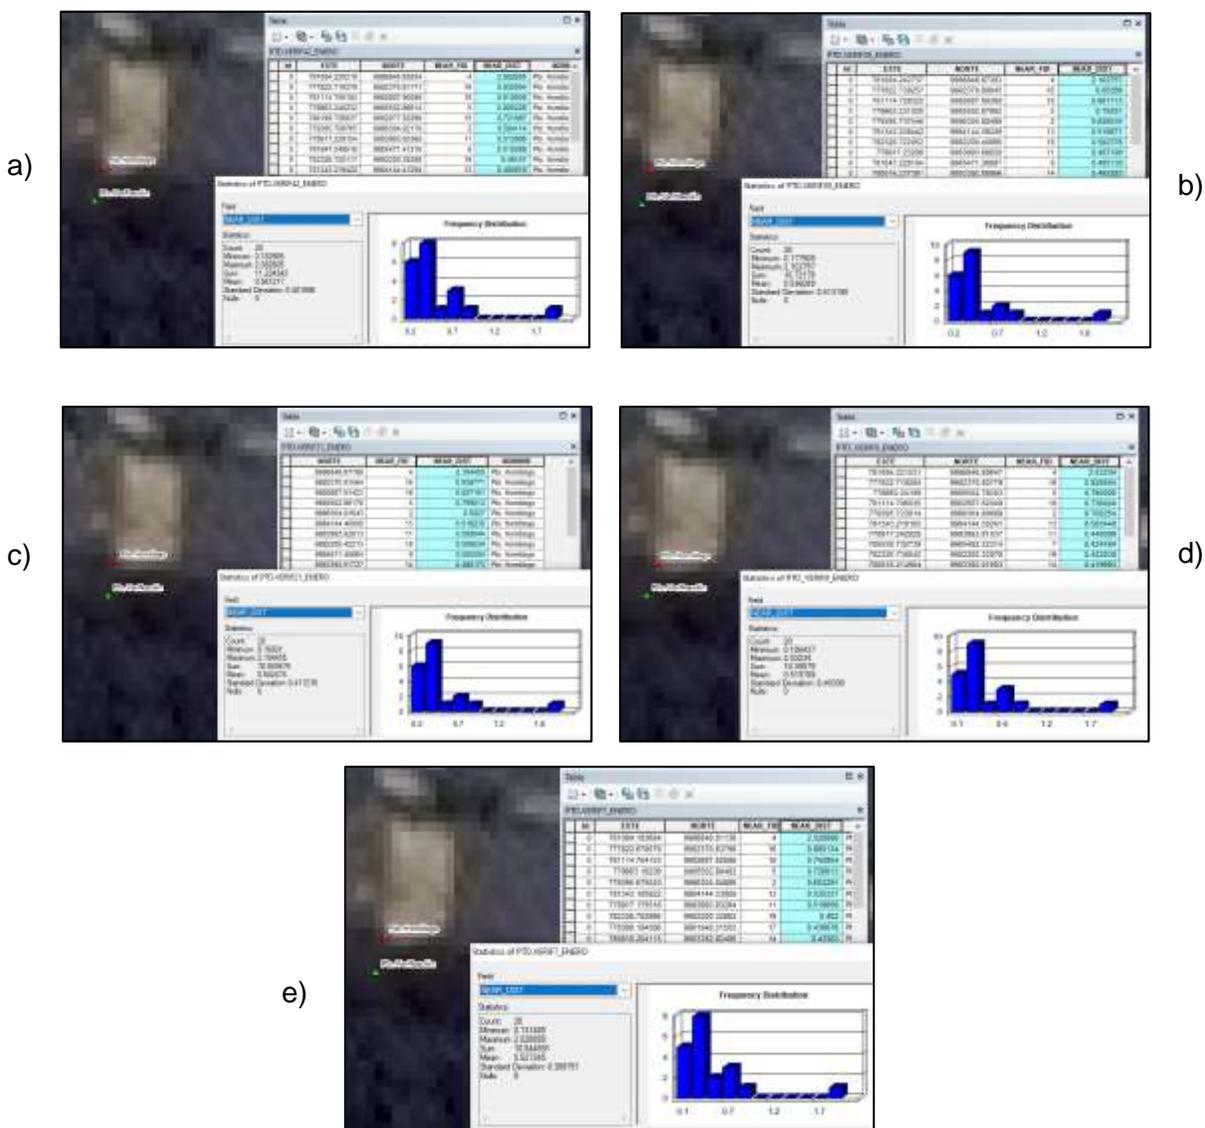
<b>Figura 53</b>	<b>Área Km<sup>2</sup></b>	<b># de puntos</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Máx (m)</b>	<b>Mín (m)</b>
a		42	0.445	0.405	1.920	0.034
b		30	0.449	0.446	2.175	0.066
c	100 km <sup>2</sup>	21	0.450	0.419	2.046	0.061
d		9	0.482	0.439	2.062	0.125
e		7	0.466	0.407	1.996	0.149

El punto 13 de los elencos de coordenadas comparativas con 42 GCP, 30 GCP, 21 GCP, 9 GCP y 7 GCP respectivamente, sobrepasa el límite de tolerancia de la exactitud planimétrica que es 1.5m, mientras que los 19 restantes no sobrepasan esta distancia en todas las ortoimágenes.

Para el año 2016, se observa en la Figura 54, que existe un desplazamiento entre los puntos, de la misma manera se ilustran los 20 puntos de validación con sus respectivos estadísticos.

Figura 54.

Desplazamientos de los puntos de referencia y sus homólogos en las ortoimágenes 2016



Nota. Imágenes estadísticas 2016: a) 42 puntos, b) 30 puntos, c) 21 puntos, d) 9 puntos, e) 7 puntos

A continuación en las Tablas 24, 25, 26, 27 y 28, se observan los elencos de coordenadas comparativas, usadas como partida para calcular la estadística clásica en las ortoimágenes del año 2016.

**Tabla 24.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con*

*42 GCP*

<b>Puntos</b>	<b>Norte (obs)</b> <b>(m)</b>	<b>Este (obs)</b> <b>(m)</b>	<b>Norte (carto)</b> <b>(m)</b>	<b>Este (carto)</b> <b>(m)</b>
1	9986160.085	777522.786	9986160.409	777522.712
2	9985856.394	778188.401	9985856.4	778188.218
3	9986305.498	779395.611	9986304.922	779395.707
4	9986693.094	780192.677	9986692.91	780192.716
5	9986846.827	781083.761	9986848.858	781084.22
6	9985502.652	778662.472	9985502.866	778663.248
7	9986073.042	779856.584	9986073.413	779856.73
8	9985492.743	780538.796	9985492.398	780538.733
9	9986007.639	781029.542	9986007.432	781029.232
10	9985470.905	781847.193	9985471.412	781847.25
11	9984446.439	778803.495	9984446.379	778803.236
12	9983993.663	778917.666	9983993.934	778917.229
13	9984534.245	780097.596	9984534.412	780097.212
14	9984144.808	781342.928	9984144.413	781343.219
15	9983392.497	780816.487	9983392.866	780816.236
16	9982977.201	780199.727	9982977.923	780199.727
17	9982370.828	777821.79	9982370.912	777822.716
18	9981940.735	778380.314	9981940.421	778380.229
19	9982687.089	781114.791	9982687.901	781114.756

20	9982199.997	782327.01	9982200.394	782326.72
----	-------------	-----------	-------------	-----------

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 25.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 30 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9986160.085	777522.786	9986160.385	777522.734
2	9985856.394	778188.401	9985856.407	778188.224
3	9986305.498	779395.611	9986304.885	779395.738
4	9986693.094	780192.677	9986692.886	780192.739
5	9986846.827	781083.761	9986848.874	781084.243
6	9985502.652	778662.472	9985502.88	778663.231
7	9986073.042	779856.584	9986073.379	779856.731
8	9985492.743	780538.796	9985492.388	780538.734
9	9986007.639	781029.542	9986007.391	781029.234
10	9985470.905	781847.193	9985471.389	781847.228

11	9984446.439	778803.495	9984446.389	778803.238
12	9983993.663	778917.666	9983993.886	778917.233
13	9984534.245	780097.596	9984534.378	780097.237
14	9984144.808	781342.928	9984144.392	781343.238
15	9983392.497	780816.487	9983392.89	780816.237
16	9982977.201	780199.727	9982977.383	780199.716
17	9982370.828	777821.79	9982370.908	777822.739
18	9981940.735	778380.314	9981940.409	778380.254
19	9982687.089	781114.791	9982687.894	781114.728
20	9982199.997	782327.01	9982200.409	782326.722

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 26.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 21 GCP*

<b>Puntos</b>	<b>Norte (obs)</b> <b>(m)</b>	<b>Este (obs)</b> <b>(m)</b>	<b>Norte (carto)</b> <b>(m)</b>	<b>Este (carto)</b> <b>(m)</b>
1	9986160.085	777522.786	9986160.427	777522.715

2	9985856.394	778188.401	9985856.411	778188.233
3	9986305.498	779395.611	9986304.916	779395.725
4	9986693.094	780192.677	9986692.904	780192.737
5	9986846.827	781083.761	9986848.878	781084.233
6	9985502.652	778662.472	9985502.892	778663.234
7	9986073.042	779856.584	9986073.422	779856.733
8	9985492.743	780538.796	9985492.419	780538.725
9	9986007.639	781029.542	9986007.411	781029.23
10	9985470.905	781847.193	9985471.407	781847.251
11	9984446.439	778803.495	9984446.419	778803.228
12	9983993.663	778917.666	9983993.928	778917.233
13	9984534.245	780097.596	9984534.404	780097.228
14	9984144.808	781342.928	9984144.4	781343.248
15	9983392.497	780816.487	9983392.917	780816.235
16	9982977.201	780199.727	9982977.424	780199.72
17	9982370.828	777821.79	9982370.916	777822.726
18	9981940.735	778380.314	9981940.42	778380.246
19	9982687.089	781114.791	9982687.914	781114.735
20	9982199.997	782327.01	9982200.422	782326.732

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 27.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 9*

*GCP*

<b>Puntos</b>	<b>Norte (obs)</b> <b>(m)</b>	<b>Este (obs)</b> <b>(m)</b>	<b>Norte (carto)</b> <b>(m)</b>	<b>Este (carto)</b> <b>(m)</b>
1	9986160.085	777522.786	9986160.291	777522.722
2	9985856.394	778188.401	9985856.306	778188.228
3	9986305.498	779395.611	9986304.807	779395.724
4	9986693.094	780192.677	9986692.821	780192.716
5	9986846.827	781083.761	9986848.806	781084.222
6	9985502.652	778662.472	9985502.782	778663.241
7	9986073.042	779856.584	9986073.311	779856.722
8	9985492.743	780538.796	9985492.323	780538.736
9	9986007.639	781029.542	9986007.791	781029.224
10	9985470.905	781847.193	9985471.31	781847.239
11	9984446.439	778803.495	9984446.327	778803.242
12	9983993.663	778917.666	9983993.81	778917.243
13	9984534.245	780097.596	9984534.299	780097.233
14	9984144.808	781342.928	9984144.302	781343.219
15	9983392.497	780816.487	9983392.817	780816.215
16	9982977.201	780199.727	9982977.307	780199.728
17	9982370.828	777821.79	9982370.808	777822.719
18	9981940.735	778380.314	9981940.322	778380.241
19	9982687.089	781114.791	9982687.82	781114.706

20	9982199.997	782327.01	9982200.321	782326.738
----	-------------	-----------	-------------	------------

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 28.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2016 con 7 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9986160.085	777522.786	9986160.319	777522.676
2	9985856.394	778188.401	9985856.319	778188.171
3	9986305.498	779395.611	9986304.849	779395.675
4	9986693.094	780192.677	9986692.827	780192.689
5	9986846.827	781083.761	9986848.811	781084.184
6	9985502.652	778662.472	9985502.805	778663.182
7	9986073.042	779856.584	9986073.316	779856.689
8	9985492.743	780538.796	9985492.333	780538.693
9	9986007.639	781029.542	9986007.804	781029.186
10	9985470.905	781847.193	9985471.316	781847.184
11	9984446.439	778803.495	9984446.313	778803.197
12	9983993.663	778917.666	9983993.833	778917.176
13	9984534.245	780097.596	9984534.324	780097.208
14	9984144.808	781342.928	9984144.339	781343.186

15	9983392.497	780816.487	9983392.825	780816.204
16	9982977.201	780199.727	9982977.325	780199.684
17	9982370.828	777821.79	9982370.838	777822.67
18	9981940.735	778380.314	9981940.315	778380.194
19	9982687.089	781114.791	9982687.827	781114.704
20	9982199.997	782327.01	9982200.329	782326.703

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

En la Tabla 29 se detallan los estadísticos media, desviación estándar, máximo y mínimo para las ortoimágenes del año 2016.

**Tabla 29.**

*Resultados de los estadísticos clásicos ortoimágenes del año 2016*

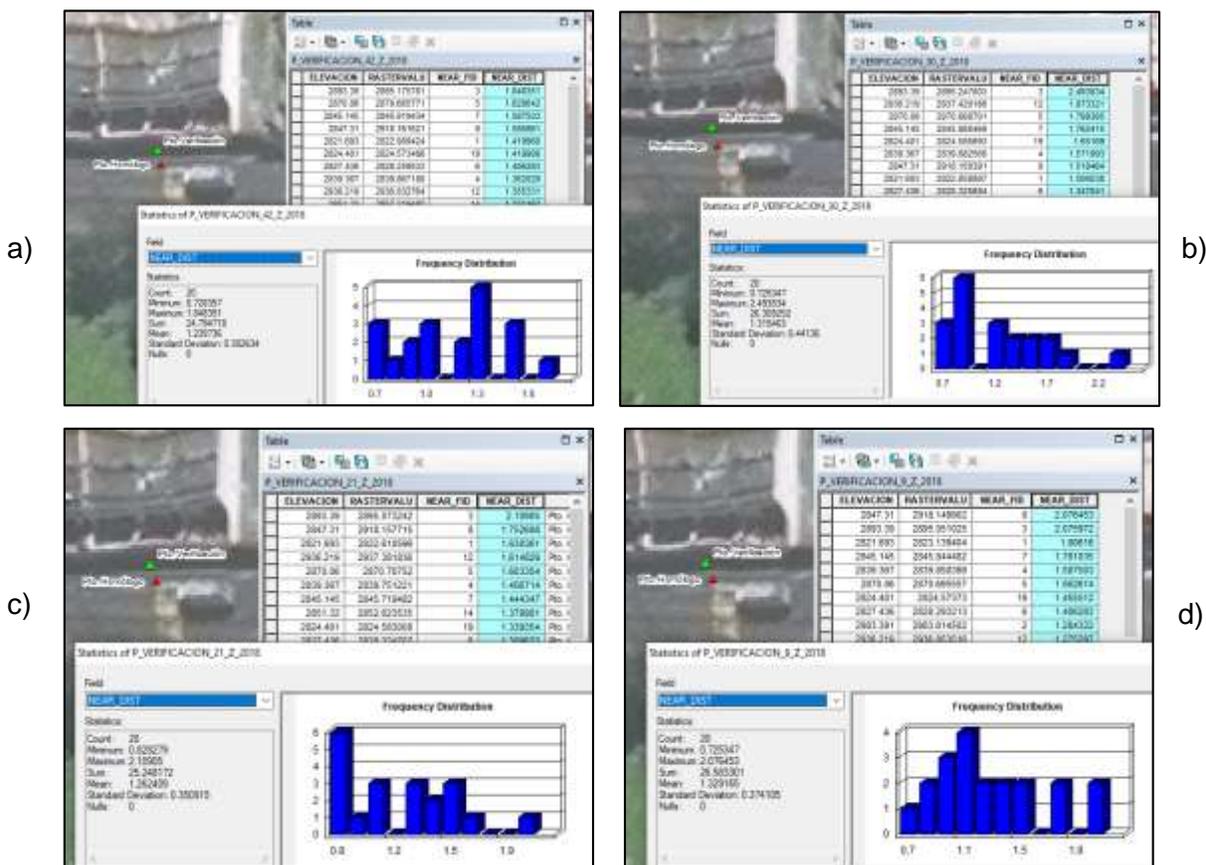
<b>Figura 54</b>	<b>Área km<sup>2</sup></b>	<b># de puntos</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Máx (m)</b>	<b>Mín (m)</b>
a	25 km <sup>2</sup>	42	0.561	0.401	2.082	0.183
b		30	0.536	0.413	2.102	0.178
c		21	0.542	0.411	2.104	0.169
d		9	0.519	0.403	2.032	0.106
e		7	0.527	0.389	2.028	0.131

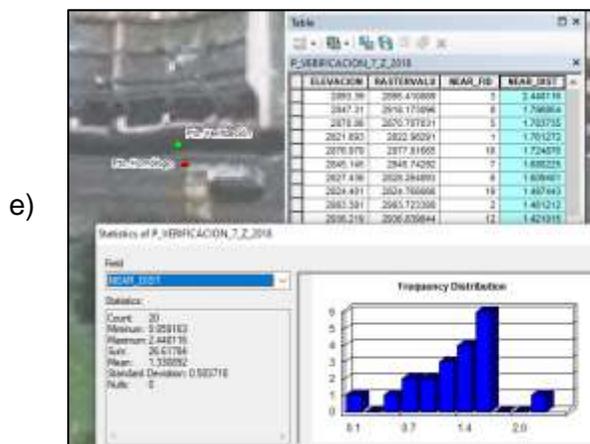
El punto 5 presentado en el elenco de coordenadas comparativas, sobrepasa la tolerancia de exactitud planimétrica de 1.5m, mientras que los 19 restantes no sobrepasan esta distancia en todas las ortoimágenes.

Respecto al año 2018, se observa en la Figura 55, que hay un desplazamiento entre los puntos; en esta se muestra el punto con más distancia; asimismo se puede observar los 20 puntos de validación con sus respectivos estadísticos.

**Figura 55.**

*Desplazamientos de los puntos de referencia y sus homólogos en las ortoimágenes 2018*





Nota. Imágenes estadísticas 2018: a) 42 puntos, b) 30 puntos, c) 21 puntos, d) 9 puntos, e) 7 puntos

En las Tablas 30, 31, 32, 33 y 34, se muestran los elencos de coordenadas comparativas con 42 GCP, 30 GCP, 21 GCP, 9 GCP y 7 GCP respectivamente, usadas como partida para calcular la estadística clásica en las ortoimágenes del año 2018.

**Tabla 30.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 42 GCP*

Puntos	Norte (obs)	Este (obs)	Norte (carto)	Este (carto)
	(m)	(m)	(m)	(m)
1	9982199.997	782327.01	9982199.15	782327.486
2	9986305.498	779395.611	9986304.175	779396.127
3	9986855.27	781084.983	9986854.357	781085.539
4	9985492.867	780535.402	9985491.081	780535.878
5	9984540.895	780096.523	9984540.234	780097.714

6	9984144.808	781342.928	9984143.697	781344.119
7	9983394.994	780810.816	9983394.068	780811.874
8	9982456.696	779107.672	9982455.426	779108.625
9	9984576.744	782003.002	9984575.219	782003.439
10	9986073.042	779856.584	9986072.579	779857.146
11	9981939.08	778373.109	9981938.101	778373.301
12	9982885.034	778411.151	9982884.32	778412.024
13	9983362.919	778146.262	9983362.072	778147.32
14	9983993.663	778917.666	9983993.028	778918.195
15	9984437.845	778804.886	9984436.654	778804.291
16	9986153.339	777520.394	9986154.08	777519.865
17	9986693.094	780192.677	9986691.903	780193.272
18	9986007.639	781029.542	9986007.044	781030.071
19	9982977.201	780199.727	9982976.354	780200.415
20	9982691.22	781122.931	9982689.95	781123.566

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 31.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 30 GCP*

<b>Puntos</b>	<b>Norte (obs)</b>	<b>Este (obs)</b>	<b>Norte (carto)</b>	<b>Este (carto)</b>
	<b>(m)</b>	<b>(m)</b>	<b>(m)</b>	<b>(m)</b>
<hr/>				

1	9982199.997	782327.01	9982199.501	782327.539
2	9986305.498	779395.611	9986304.069	779396.087
3	9986855.27	781084.983	9986854.106	781085.406
4	9985492.867	780535.402	9985490.486	780536.143
5	9984540.895	780096.523	9984539.81	780097.661
6	9984144.808	781342.928	9984143.353	781343.986
7	9983394.994	780810.816	9983394.042	780811.769
8	9982456.696	779107.672	9982455.267	779108.704
9	9984576.744	782003.002	9984575.259	782003.32
10	9986073.042	779856.584	9986072.301	779857.272
11	9981939.08	778373.109	9981938.471	778373.731
12	9982885.034	778411.151	9982884.611	778411.945
13	9983362.919	778146.262	9983361.411	778147.373
14	9983993.663	778917.666	9983992.774	778918.008
15	9984437.845	778804.886	9984436.813	778804.727
16	9986153.339	777520.394	9986154.133	777519.918
17	9986693.094	780192.677	9986692.168	780193.008
18	9986007.639	781029.542	9986006.448	781030.005
19	9982977.201	780199.727	9982976.678	780200.362
20	9982691.22	781122.931	9982689.871	781123.884

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 32.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con  
21 GCP*

<b>Puntos</b>	<b>Norte (obs)</b> <b>(m)</b>	<b>Este (obs)</b> <b>(m)</b>	<b>Norte (carto)</b> <b>(m)</b>	<b>Este (carto)</b> <b>(m)</b>
1	9982199.997	782327.01	9982199.362	782327.671
2	9986305.498	779395.611	9986304.281	779396.696
3	9986855.27	781084.983	9986854.437	781085.102
4	9985492.867	780535.402	9985490.883	780536.116
5	9984540.895	780096.523	9984539.771	780097.449
6	9984144.808	781342.928	9984143.379	781343.656
7	9983394.994	780810.816	9983394.068	780811.742
8	9982456.696	779107.672	9982455.426	779108.36
9	9984576.744	782003.002	9984575.1	782003.611
10	9986073.042	779856.584	9986072.301	779856.954
11	9981939.08	778373.109	9981938.207	778373.427
12	9982885.034	778411.151	9982884.399	778411.865
13	9983362.919	778146.262	9983361.596	778147.188
14	9983993.663	778917.666	9983992.631	778918.023
15	9984437.845	778804.886	9984436.469	778804.78
16	9986153.339	777520.394	9986154.344	777519.918
17	9986693.094	780192.677	9986692.181	780193.391
18	9986007.639	781029.542	9986006.845	781029.86
19	9982977.201	780199.727	9982976.817	780200.56

20	9982691.22	781122.931	9982689.963	781123.394
----	------------	------------	-------------	------------

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 33.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 9 GCP*

Puntos	Norte (obs)	Este (obs)	Norte (carto)	Este (carto)
	(m)	(m)	(m)	(m)
1	9982199.997	782327.01	9982199.336	782327.308
2	9986305.498	779395.611	9986303.963	779396.564
3	9986855.27	781084.983	9986854.013	781085.248
4	9985492.867	780535.402	9985490.949	780536.196
5	9984540.895	780096.523	9984539.943	780097.793
6	9984144.808	781342.928	9984143.432	781343.669
7	9983394.994	780810.816	9983393.936	780811.742
8	9982456.696	779107.672	9982455.175	779108.598
9	9984576.744	782003.002	9984574.809	782003.756
10	9986073.042	779856.584	9986072.367	779857.259
11	9981939.08	778373.109	9981938.128	778373.704
12	9982885.034	778411.151	9982884.538	778412.011
13	9983362.919	778146.262	9983361.9	778147.029
14	9983993.663	778917.666	9983992.671	778917.864

15	9984437.845	778804.886	9984436.654	778804.965
16	9986153.339	777520.394	9986154.212	777519.719
17	9986693.094	780192.677	9986692.135	780193.173
18	9986007.639	781029.542	9986006.581	781030.104
19	9982977.201	780199.727	9982976.54	780200.322
20	9982691.22	781122.931	9982689.91	781123.566

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

**Tabla 34.**

*Resultados del elenco de coordenadas comparativas para las ortoimágenes del año 2018 con 7 GCP*

<b>Puntos</b>	<b>Norte (obs) (m)</b>	<b>Este (obs) (m)</b>	<b>Norte (carto) (m)</b>	<b>Este (carto) (m)</b>
1	9982199.997	782327.01	9982199.415	782327.486
2	9986305.498	779395.611	9986304.043	779396.603
3	9986855.27	781084.983	9986853.815	781085.115
4	9985492.867	780535.402	9985490.565	780536.235
5	9984540.895	780096.523	9984540.022	780097.237
6	9984144.808	781342.928	9984143.3	781343.881
7	9983394.994	780810.816	9983393.83	780811.927
8	9982456.696	779107.672	9982455.34	779108.664
9	9984576.744	782003.002	9984575.1	782003.703

10	9986073.042	779856.584	9986072.566	779857.034
11	9981939.08	778373.109	9981938.207	778373.982
12	9982885.034	778411.151	9982884.604	778411.945
13	9983362.919	778146.262	9983361.768	778147.095
14	9983993.663	778917.666	9983992.737	778917.931
15	9984437.845	778804.886	9984436.489	778804.688
16	9986153.339	777520.394	9986153.392	777520.42
17	9986693.094	780192.677	9986691.639	780193.603
18	9986007.639	781029.542	9986006.581	781030.124
19	9982977.201	780199.727	9982976.341	780200.521
20	9982691.22	781122.931	9982689.838	781123.506

*Nota.* Norte (obs), Este (obs): coordenadas de validación tomadas en campo; Norte (carto), Este (carto): coordenadas marcadas en la ortoimagen.

En la Tabla 35 se detallan los estadísticos de media, desviación estándar, máximo y mínimo para las ortoimágenes del año 2018.

**Tabla 35.**

*Resultados de los estadísticos clásicos ortoimágenes del año 2018*

<b>Figura 55</b>	<b>Área km<sup>2</sup></b>	<b># de puntos</b>	<b>Media (m)</b>	<b>Desv. Est (m)</b>	<b>Máx (m)</b>	<b>Mín (m)</b>
a		42	1.240	0.310	1.848	0.728
b	25 km <sup>2</sup>	30	1.314	0.454	2.494	0.725
c		21	1.262	0.360	2.109	0.828

d	9	1.329	0.384	2.076	0.725
e	7	1.331	0.517	2.448	0.059

Los puntos 4, 6, 8 y 9 de la Tabla 30, los puntos 2, 4, 5, 6, 8, 9, 13 y 20 de la Tabla 31, los puntos 2, 4, 6, 9 y 13 de la Tabla 32, los puntos 2, 4, 5, 6, 8 y 9 de la Tabla 33 y los puntos 2, 4, 6, 7, 8, 9, 17 y 19 de la Tabla 34, son los puntos que sobrepasan el error máximo tolerable en dirección horizontal para escala 1:5000 de 1.5m según la normativa IGM, indicando que al sobrepasar esta distancia no se puede llegar a cumplir con la exactitud posicional para la norma IGM y la norma NSSDA.

### **Resultados de evaluación exactitud posicional planimétrica con estadística normativa de las ortoimágenes**

Para la validación de las ortoimágenes es necesario aplicar las fórmulas de RMSE<sub>x</sub>, RMSE<sub>y</sub>, RMSE<sub>r</sub>, la exactitud posicional al 95% aplicando la norma National Standard for Spatial Data Accuracy (NSSDA) y la norma IGM al 90%. En la Tabla 36 se aprecian los resultados obtenidos para cada una de las ortoimágenes de los diferentes años y número de puntos de control (GCP).

**Tabla 36.**

*Resultados estadística normativa de las ortoimágenes (exactitud planimétrica)*

Año	Área Km <sup>2</sup>	# Puntos	RMSE <sub>x</sub> (m)	RMSE <sub>y</sub> (m)	RMSE <sub>r</sub> (m)	Exactitud	Exactitud
						NSSDA r al 95% (m)	IGM r al 90% (m)
		42	0.459	0.389	0.601	1.037	0.910

			30	0.547	0.320	0.634	1.061	0.931
Ortoimágenes 2014	100 km <sup>2</sup>		21	0.477	0.390	0.616	1.060	0.930
			9	0.511	0.405	0.652	1.088	0.955
			7	0.474	0.400	0.620	1.068	0.937
			42	0.353	0.593	0.690	1.158	1.015
Ortoimágenes 2016	25 km <sup>2</sup>		30	0.355	0.582	0.677	1.139	0.999
			21	0.354	0.582	0.681	1.144	1.004
			9	0.351	0.556	0.658	1.110	0.973
			7	0.348	0.556	0.656	1.106	0.970
			42	0.733	1.045	1.276	2.175	1.907
Ortoimágenes 2018	25 km <sup>2</sup>		30	0.723	1.183	1.386	2.332	2.045
			21	0.660	1.132	1.310	2.193	1.923
			9	0.711	1.184	1.381	2.318	2.033
			7	0.728	1.223	1.423	2.387	2.093
			42	0.733	1.045	1.276	2.175	1.907

*Nota:* RMSx (Error en dirección x “Este”); RMSy (Error en dirección y “Norte”); RMSEr (Error lineal horizontal que incluye errores de coordenadas x como y); Exactitud (Precisión horizontal con un nivel de confianza del 95 %).

El error máximo tolerable en dirección horizontal para escala 1:5000 es de 1.5m según la normativa IGM; en la Tabla 34 se reflejan los valores de exactitud posicional basados en la norma NSSDA de cada una de las ortoimágenes, observando que las ortoimágenes de los años 2014 y 2016 con una resolución espacial de 0.40m y 0.50m, con nadir 13.1° y 26.0° respectivamente, cumplen con la normativa; mientras que la imagen del 2018 con resolución espacial de 0.50m y un nadir de 27.7° no cumple.

### Evaluación exactitud posicional altimétrica del MDS

En la Tabla 37 encontrará el  $RMSE_z$ , la exactitud vertical de los modelos a través de la norma NSSDA; así como también, los estadísticos: mínimo, máximo, media, desviación estándar.

**Tabla 37.**

*Resultados estadísticos MDS (exactitud altimétrica)*

Estadística	Área	#	Dist. Min	Dist. Max	Media	Desv.	RMSEz	Exactitud
	Km <sup>2</sup>	Puntos	(m)	(m)	(m)	Est. (m)	(m)	v al 95% (m)
MDS 2014	100 km <sup>2</sup>	42	-0.742	3.367	0.498	0.883	0.994	1.949
		30	-0.622	2.700	0.498	0.749	0.884	1.732
		21	-0.675	3.313	0.515	0.866	0.989	1.938
		9	-0.821	3.481	0.536	0.942	1.063	2.083
		7	-0.857	3.598	0.560	1.005	1.128	2.211
MDS 2016	25 km <sup>2</sup>	42	-0.521	1.315	0.206	0.529	0.555	1.088
		30	-0.505	0.813	0.064	0.388	0.384	0.753
		21	-0.478	1.158	0.162	0.487	0.502	0.983
		9	-0.374	1.244	0.244	0.419	0.476	0.932
		7	-0.447	1.540	0.196	0.491	0.517	1.014
MDS 2018	25 km <sup>2</sup>	42	-0.118	2.371	0.598	0.620	0.850	1.666
		30	-0.161	1.858	0.601	0.537	0.797	1.561
		21	-0.123	1.683	0.561	0.530	0.763	1.496
		9	-0.247	1.661	0.555	0.514	0.748	1.465
		7	-0.200	2.963	0.663	0.762	0.995	1.951

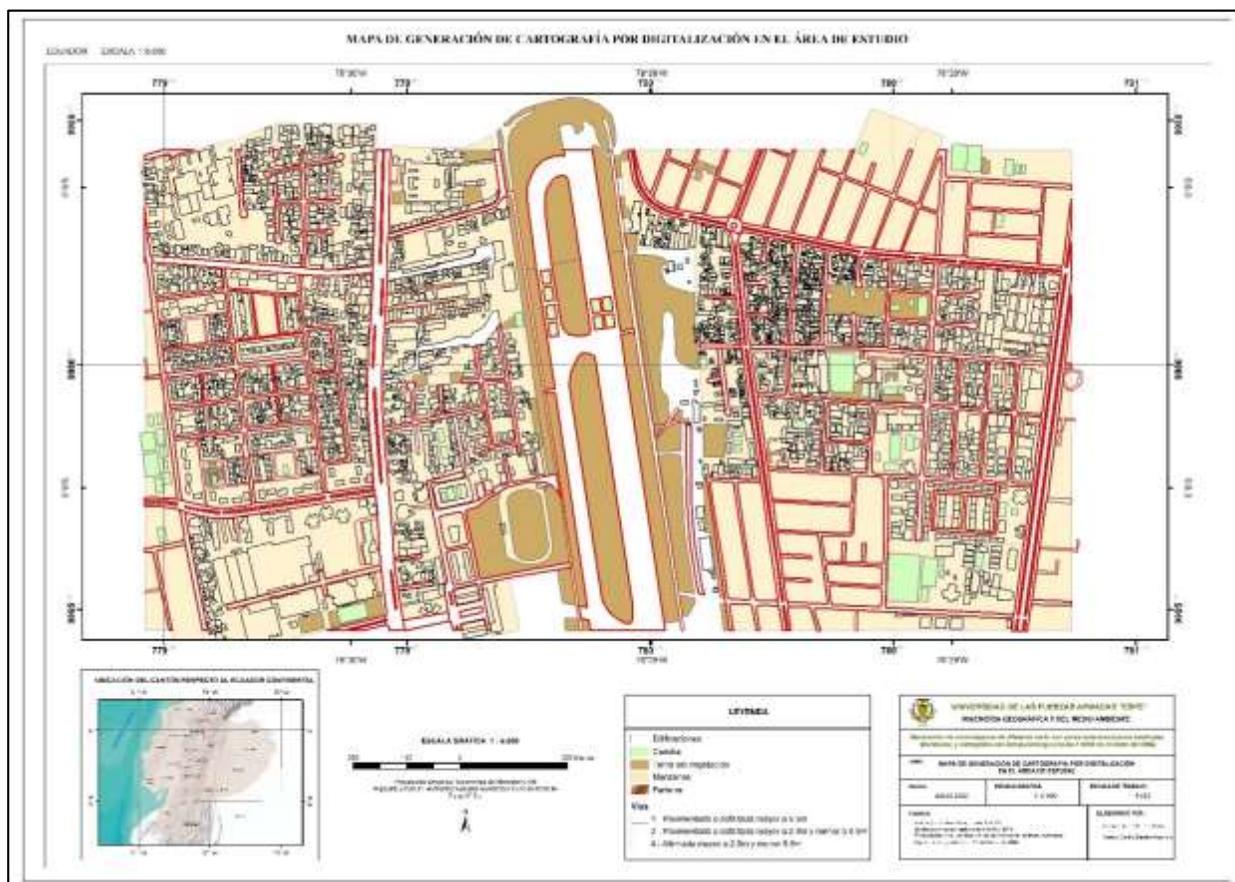
El error máximo permisible en la exactitud vertical a escala 1:5000 es de 1.25 m, analizando los resultados obtenidos, se puede decir que los Modelos Digitales de Superficie del año 2016 cumplen con la normativa IGM, ya que la exactitud no sobrepasa 1.25 m, cabe recalcar que esta es una zona plana; mientras que los Modelos Digitales de Superficie de los años 2014 y 2018 no cumplen con la normativa, como se observa en la Tabla 37.

### **Resultado de topología pasada en la cartografía digitalizada**

Se digitalizaron 200 ha de una ortoimagen de 100 km<sup>2</sup> del año 2014, como se indicó en el Capítulo III, el resultado de la digitalización se incorporó en una GBD, en cada una de las entidades se pasó las reglas topológicas dependiendo de su geometría, la información de la GDB tuvo su proceso de catalogación según el Instituto Geográfico Militar, obteniendo como resultado un mapa como se observa en la Figura 56.

Figura 56.

Mapa de cartografía por digitalización

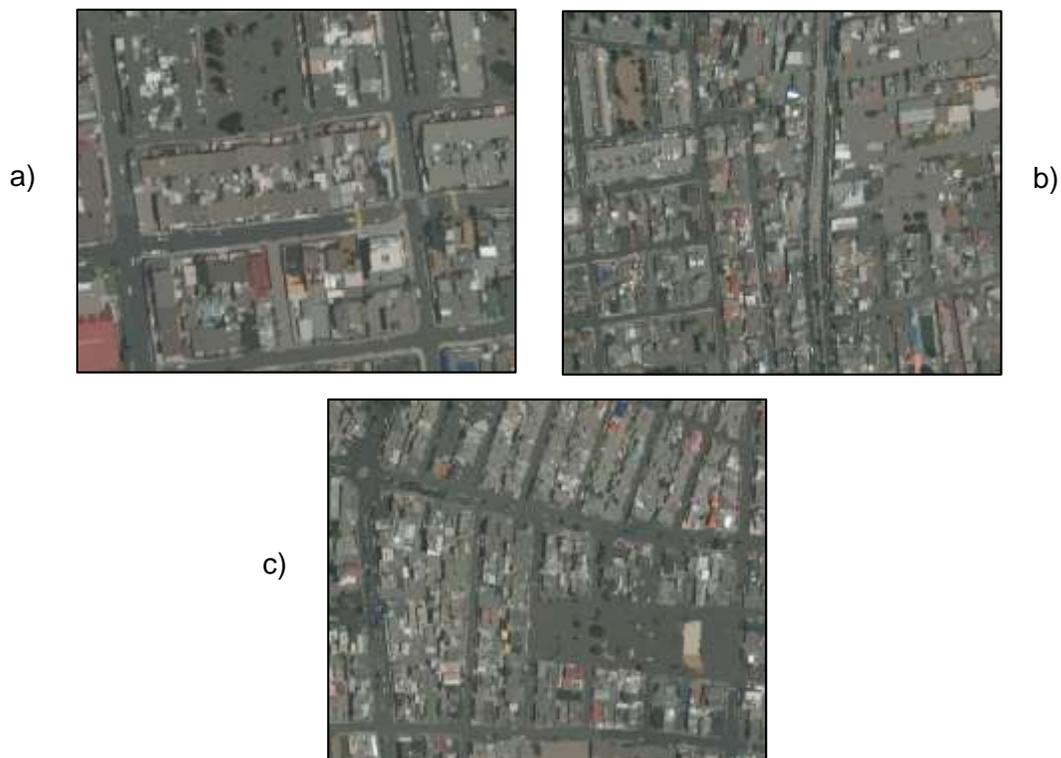


El resultado del proceso de catalogación se lo puede evidenciar dentro de cada una de las entidades digitalizadas, la Figura 57, representa un ejemplo de catalogación de canchas.



**Figura 58.**

*Ejemplo de segmentaciones de la ortoimagen*



*Nota.* a) Detalle espacial y espectral: 10, Tamaño de segmento mínimo en píxeles: 5; b) Detalle espacial y espectral: 18, Tamaño de segmento mínimo en píxeles: 10; c) Detalle espacial y espectral: 20, Tamaño de segmento mínimo en píxeles: 5

Al hacer una comparación visual entre las 3 combinaciones de la segmentación se puede evidenciar la pérdida de información entre vías, tierras sin información y canchas lo que provocará inconsistencias en el modelo de entrenamiento para extracción de cartografía, las combinaciones dependerá del objetivo de la extracción de cartografía, adicional en este proyecto se puede observar que a mayor valor de detalle espacial y espectral y menor valor del tamaño de segmento mínimo en píxeles se tiene una mejor discriminación de información cuando existen diferentes colores, texturas y contrastes en la imagen.

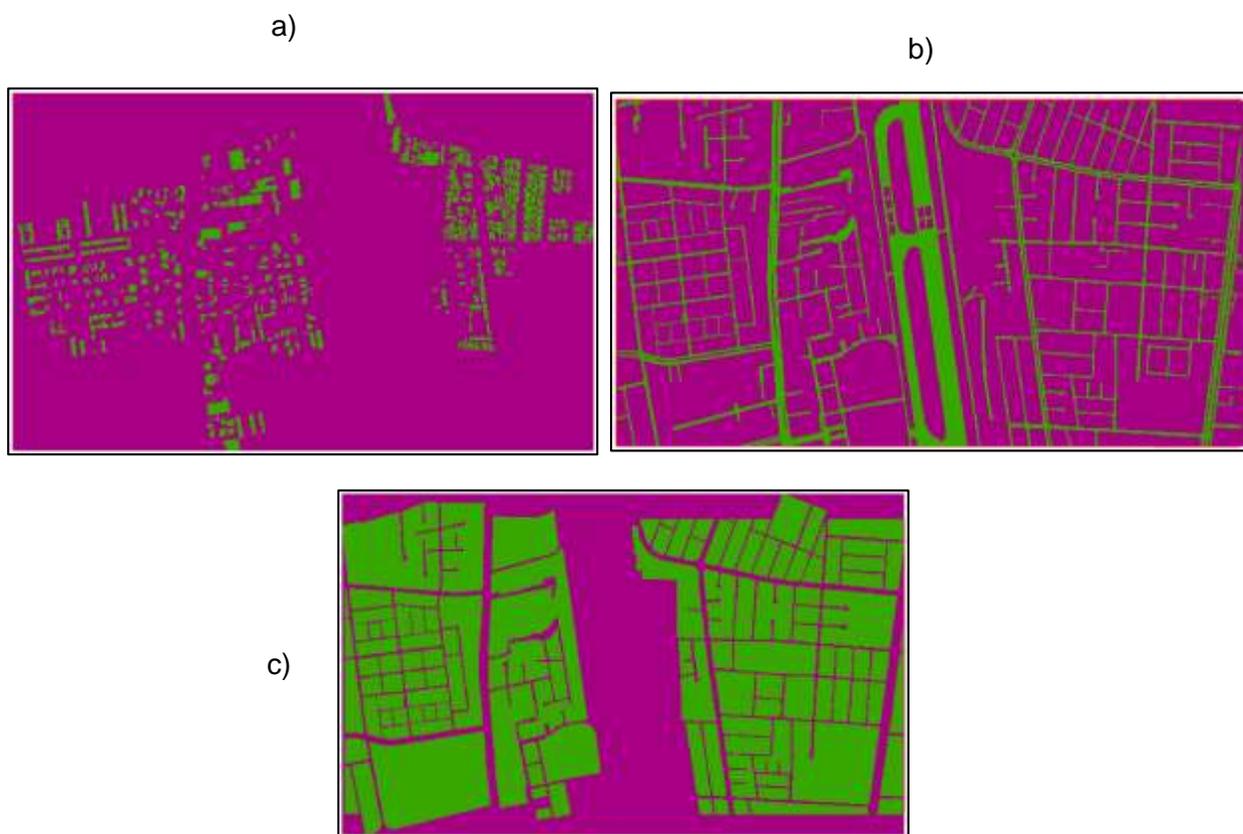
De acuerdo a lo expuesto, la combinación para la segmentación escogida es la que corresponde al literal c, misma que permite mejo discriminación visual de la información de la ortoimagen.

### Resultados de extracción de datos de entrenamiento

En la Figura 59 se puede encontrar el resultado de la relcasificación obtenida a partir de la digitalización de muestras de Deep Learning para los polígonos de edificaciones, vías y manzanas.

### Figura 59.

*Resultados de extracción de datos de entrenamiento*



*Nota.* a) Resultado de extracción de datos de entrenamiento para edificaciones; b) Resultado de extracción de datos de entrenamiento para vías; c) Resultado de extracción de datos de entrenamiento para manzanas

Este resultado será de utilidad para la generación de los “chips” mismos que van a contener las características esenciales para que el modelo genere óptimos resultados, la Figura 59, muestra la reclasificación de los polígonos de edificaciones, donde el color rosado muestra las zonas sin información y las zonas de color verde muestran los valores en los cuales se muestra información, es decir donde el software ha detectado una edificación.

### Resultados del entrenamiento del modelo

Para analizar este resultado es indispensable identificar las combinaciones aplicadas y número de épocas al generar los chips en la herramienta *Train Deep Learning Model*, cada combinación permitirá obtener una menor o mayor discriminación de la información para generar cartografía; adicional mientras más épocas se coloque en la herramienta mayor cantidad de tiempo se invierte, en las Tablas 38, 39 y 40 se detallan los tiempos invertidos para la generación de chips con cada una de las combinaciones, además se podrá visualizar la cantidad de épocas necesarias para que el modelo deje de aprender.

**Tabla 38.**

*Resultados de entrenamiento del modelo para edificaciones*

Edificaciones	Épocas	Tipo de modelo	Backbone Model	Tiempo de Procesamiento Train Model	Épocas recorridas
	100	U-Net	ResNet-34	0:07:15	28

200	BDCN Edge Detector	ResNet-34	0:09:41	45
200	U-Net	ResNet-152	2:41:56	34
200	BDCN Edge Detector	ResNet-152	2:26:31	46
5	U-Net	ResNet-152	0:28:44	5

En esta tabla se puede observar que la combinación que más tiempo ha tomado es la correspondiente al tipo de modelo U-Net, con un modelo Backbone ResNet-152, cabe recalcar que de las 200 épocas colocadas en el modelo, fueron necesarias 34 para que esta combinación aprenda y genere buenos resultados, sin embargo la combinación que más rápido ha realizado su proceso es la que corresponde a un tipo de modelo U-Net, con un modelo Backbone ResNet-34, y se han recorrido 28 épocas de las 100 colocadas. Al cambiar el tipo de modelo a BDCN Edge Detector se puede observar que el modelo necesita más épocas para aprender. Cuando se coloca un modelo Backbone ResNet-34 el tiempo de procesamiento es menor al del ResNet-152.

**Tabla 39.**

*Resultados de entrenamiento del modelo para vías*

	Épocas	Tipo de modelo	Backbone Model	Tiempo de Procesamiento Train Model	Épocas recorridas
Vías	200	BDCN Edge Detector	ResNet-34	0:09:25	24
	200	U-Net	ResNet-152	4:48:31	52

200	BDCN Edge Detector	ResNet-152	2:52:14	43
-----	-----------------------	------------	---------	----

En esta tabla se puede observar que la combinación que más tiempo ha tomado es la correspondiente al tipo de modelo U-Net, con un modelo Backbone ResNet-152; la misma combinación cuando se aplica en las edificaciones; sin embargo en esta combinación fueron necesarias 52 para que esta combinación aprenda y genere buenos resultados, así mismo la combinación que más rápido ha realizado su proceso es la que corresponde a un tipo de modelo BDCN, con un modelo Backbone ResNet-34, y se han recorrido 24 épocas de las 200 colocadas. Al cambiar el tipo de modelo a BDCN Edge y mantener el valor del modelo Backbone se observa que el tiempo de procesamiento también es elevado.

**Tabla 40.**

*Resultados de entrenamiento del modelo para manzanas*

	Épocas	Tipo de modelo	Backbone Model	Tiempo de Procesamiento Train Model	Épocas recorridas
Manzanas	200	U-Net	ResNet-34	0:27:32	21
	200	BDCN Edge Detector	ResNet-34	0:27:57	14
	200	U-Net	ResNet-152	2:36:07	27
	200	BDCN Edge Detector	ResNet-152	1:15:20	32

En esta tabla se puede observar que la combinación que más ha tiempo ha tomado es la correspondiente al tipo de modelo U-Net, con un modelo Backbone ResNet-152, de las 200

épocas colocadas en el modelo, fueron necesarias 32 para que esta combinación aprenda y genere buenos resultados, sin embargo la combinación que más rápido ha realizado su proceso es la que corresponde a un tipo de modelo U-Net, con un modelo Backbone ResNet-34, y se han recorrido 21 épocas de las 200 colocadas.

En las tres entidades en las cuales se generarán los modelos de aprendizaje se observa una similitud entre las combinaciones del tipo de modelo U-Net y el modelo Backbone ResNet-152, en el caso de este último se debe a la cantidad de información que el modelo posee en su base más de un millón de imágenes guía y 152 capas de profundidad las cuales permitirán generar un mejor modelo de aprendizaje, mientras que el modelo Backbone ResNet-34, posee solo 34 capas de profundidad.

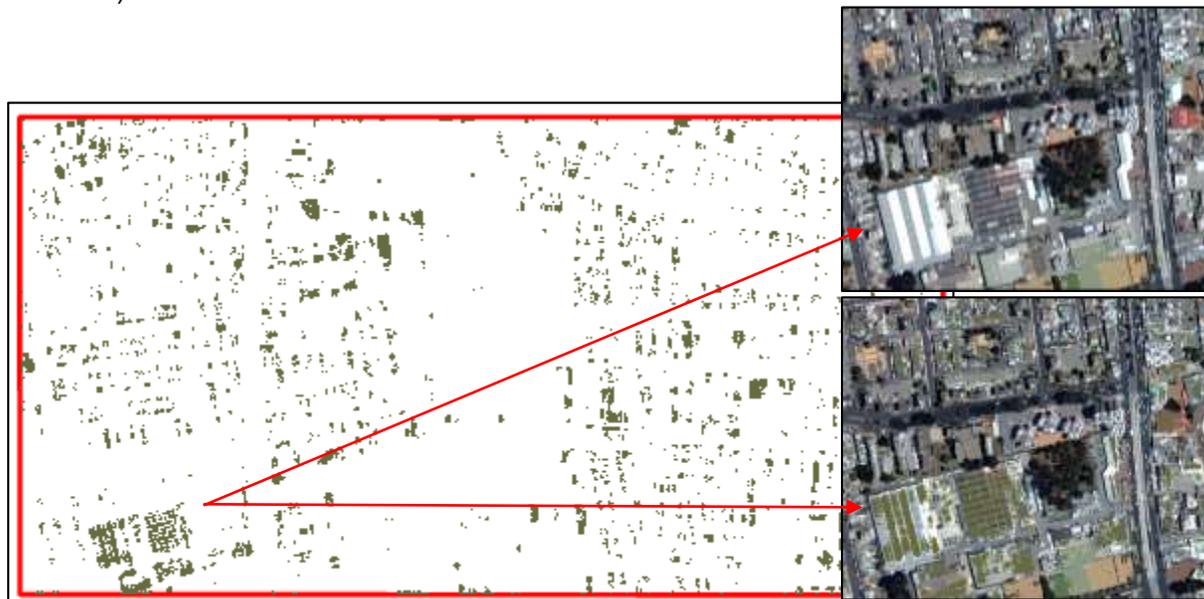
### **Resultados de la clasificación de píxeles mediante Deep Learning**

El resultado de clasificación de píxeles está enlazado al resultado de entrenamiento del modelo, ya que a partir de este y de sus combinaciones se podrá generar un resultado preliminar de la cartografía, los resultados para edificaciones se visualizan en la Figura 60; para vías los resultados se visualizan en la Figura 61; finalmente para manzanas los resultados se visualizan en la Figura 62.

**Figura 60.**

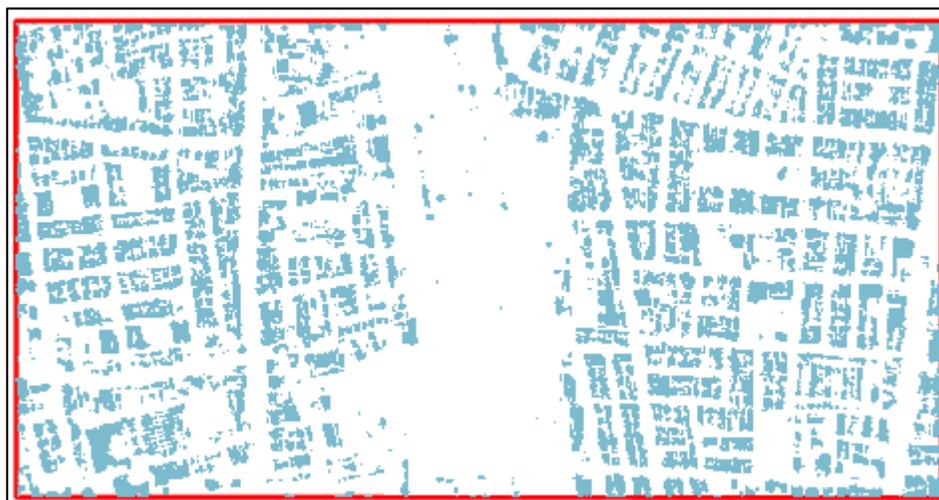
*Resultados de la clasificación de píxeles mediante deep learning - edificaciones*

a)



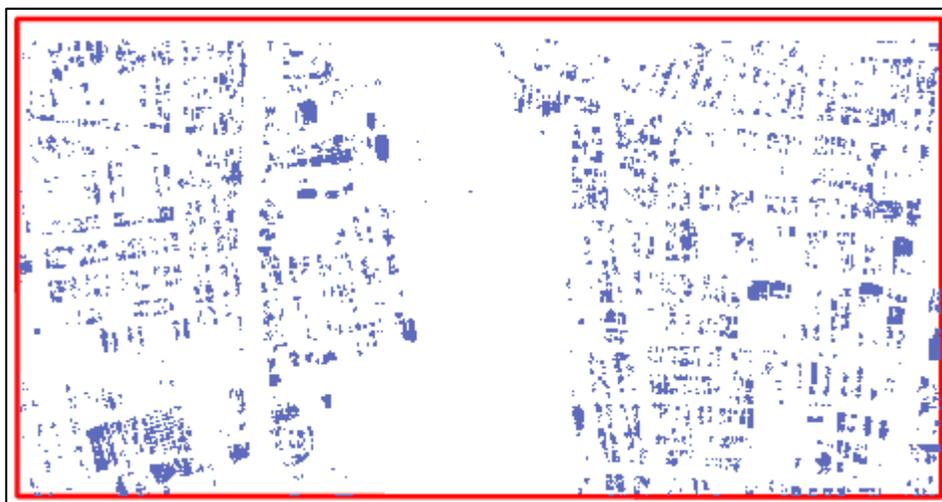
El tiempo invertido en esta combinación fue de 10 minutos con 5 segundos, se puede observar que no existe una buena discriminación de las edificaciones, las edificaciones que se visualizan en la figura son aquellas que poseen un techo de color claro y aquellas que poseen una separación entre cada edificación.

b)



El tiempo invertido en esta combinación fue de 25 minutos con 1 segundo, se puede observar que a diferencia de la anterior combinación existe una buena discriminación de las edificaciones, aunque éstas llegan a agruparse entre sí se puede observar que la cantidad es mayor a la del modelo anterior.

c)



El tiempo invertido en esta combinación fue de 1 hora 2 minutos con 10 segundos, al igual que la primera combinación se puede observar que no existe una buena discriminación de las edificaciones sin embargo la cantidad de edificaciones es mayor.

d)



El tiempo invertido en esta combinación fue de 1 hora 2 minutos con 37 segundos, se puede observar que existe una mayor cantidad de edificaciones que los otros modelos, sin embargo varias edificaciones se han agrupado en un solo polígono, lo que podría dificultar el proceso de generalización.

e)



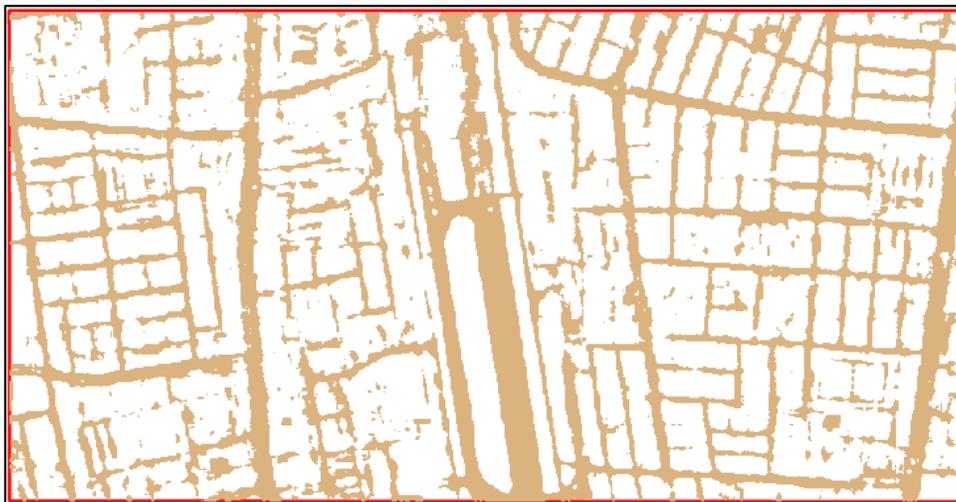
El tiempo invertido en esta combinación fue de 12 minutos con 15 segundos, se puede observar que a diferencia de las anteriores combinaciones la cantidad de edificaciones es menor, esto puede ser debido a la cantidad de épocas en el modelo de entrenamiento.

*Nota.* a) Clasificación de píxeles de Modelo Unet y Backbone Model Resnet 34 con 100 épocas en los polígonos de edificaciones, b) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de edificaciones, c) Clasificación de píxeles de Modelo Unet y Backbone Model Resnet 152 con 200 épocas en los polígonos de edificaciones, d) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de edificaciones, e) Clasificación de píxeles de Modelo Unet y Backbone Model Resnet 152 con 5 épocas en los polígonos de edificaciones

**Figura 61.**

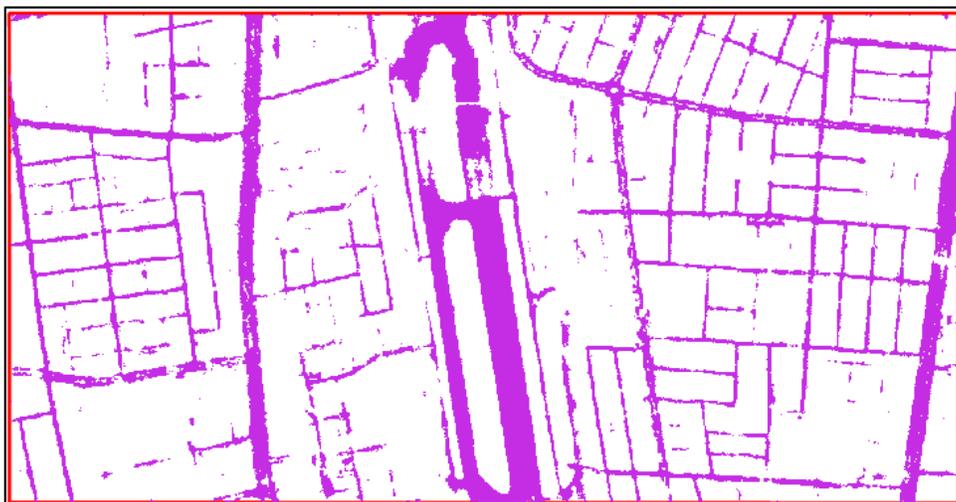
*Resultados de la clasificación de píxeles mediante deep learning – vías*

a)



El tiempo invertido en esta combinación fue de 21 minutos con 9 segundos, se puede observar que que en esta combinación, algunas se confunden con terrenos baldíos y la información faltante, es decir los huecos en su mayoría corresponde a parterres y a autos, sin embargo existe una buena discriminación de la información.

b)



El tiempo invertido en esta combinación fue de 39 minutos con 1 segundos, a pesar de que el tiempo de procesamiento es más alto que la combinación anterior, la cantidad de elementos que se obtuvieron de la clasificación es más escasa, se puede observar que las vías ya no se confunden con terrenos baldíos e información faltante, pero existe falta de información, principalmente en las vías de segundo y cuarto orden.

c)



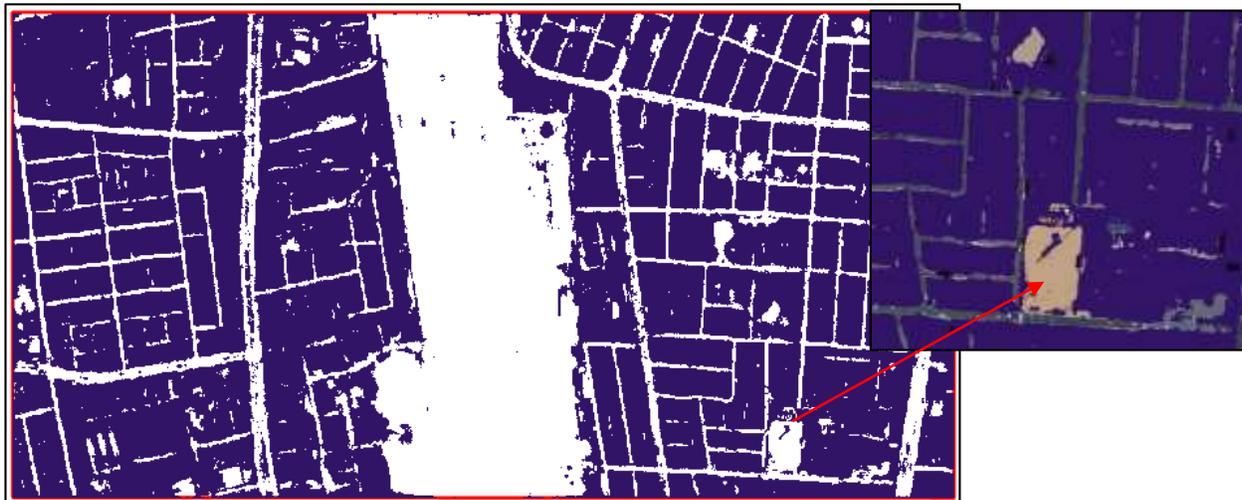
El tiempo invertido en esta combinación fue de 1 hora 2 minutos con 3 segundos, esta es la combinación que más tiempo ha tomado para extraer información, la cantidad de elementos que se obtuvieron de la clasificación es mejor que la de la primera y segunda combinación ya que con esta a pesar de que los elementos se confunden con terrenos baldíos e información faltante, existe mejor discriminación de información, principalmente de las vías de segundo y cuarto orden.

*Nota.* a) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de vías, b) Clasificación de píxeles de Modelo UNet y Backbone Model Resnet 152 con 200 épocas en los polígonos de vías, c) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de vías

**Figura 62.**

*Resultados de la clasificación de píxeles mediante deep learning - manzanas*

a)



El tiempo invertido en esta combinación fue de 21 minutos con 9 segundos, parte de la información no extraída durante el proceso corresponde a las canchas, adicional se puede observar que también se han extraído polígonos del parterre y del redondel.

b)

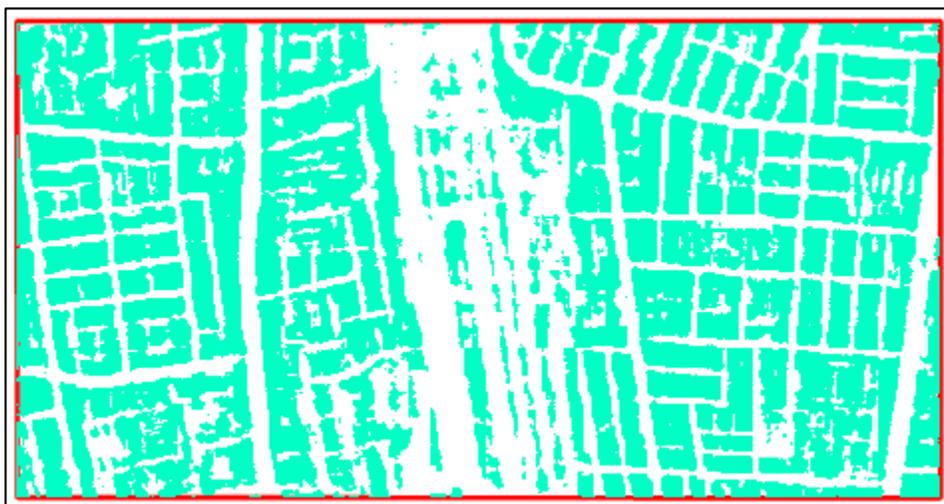


El tiempo invertido en esta combinación fue de 39 minutos con 1 segundos, en esta combinación no se han extraído polígonos del parterre y del redondel, sin embargo se tiene polígonos de las zonas sin información como son las correspondientes al aeropuerto.

c)



d)



En este proceso tiempo invertido en esta combinación fue de 47 minutos con 36 segundos, en esta combinación también se han extraído polígonos del parterre y del redondel,

sin embargo esta combinación nos ha tomado en cuenta la información de canchas, es decir ha intentado generalizar la información que se encuentra dentro de las manzanas.

*Nota.* a) Clasificación de píxeles de Modelo Unet y Backbone Model Resnet 34 con 200 épocas en los polígonos de manzanas, b) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de manzanas, c) Clasificación de píxeles de Modelo UNet y Backbone Model Resnet 152 con 200 épocas en los polígonos de manzanas d) Clasificación de píxeles de Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de manzanas. En la Tabla 36, se muestra un resumen de los tiempos invertidos para obtener el modelo de entrenamiento y la clasificación de píxeles de cada una de las entidades a evaluar.

**Tabla 41.**

*Resultados de entrenamiento y clasificación del modelo para edificaciones, vías y manzanas*

	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
	200	U-Net	ResNet-34	0:27:32	21	0:21:09
Manzanas	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

La entidad que más tiempo ha invertido en el procesamiento Train model y en la clasificación de píxeles es la que corresponde a vías con un tiempo de 4 horas 45 minutos 31 segundos y 1 hora 15 minutos 10 segundos respectivamente, sin embargo como se pudo observar en la Figura 61b, el tiempo invertido no asegura que el modelo sea el mejor.

### Resultados del proceso de generalización

Como se indicó en el Capítulo III para este proceso fue necesaria la creación de un modelo diseñado en Model Builder, este modelo permitirá pasar el resultado de clasificación de píxeles por varios filtros que mejorarán la extracción de cartografía, en las Figuras 63, 64 y 65 se pueden observar los resultados obtenidos para edificaciones, vías y manzanas respectivamente.

**Figura 63.**

*Resultados del proceso de generalización para edificaciones*



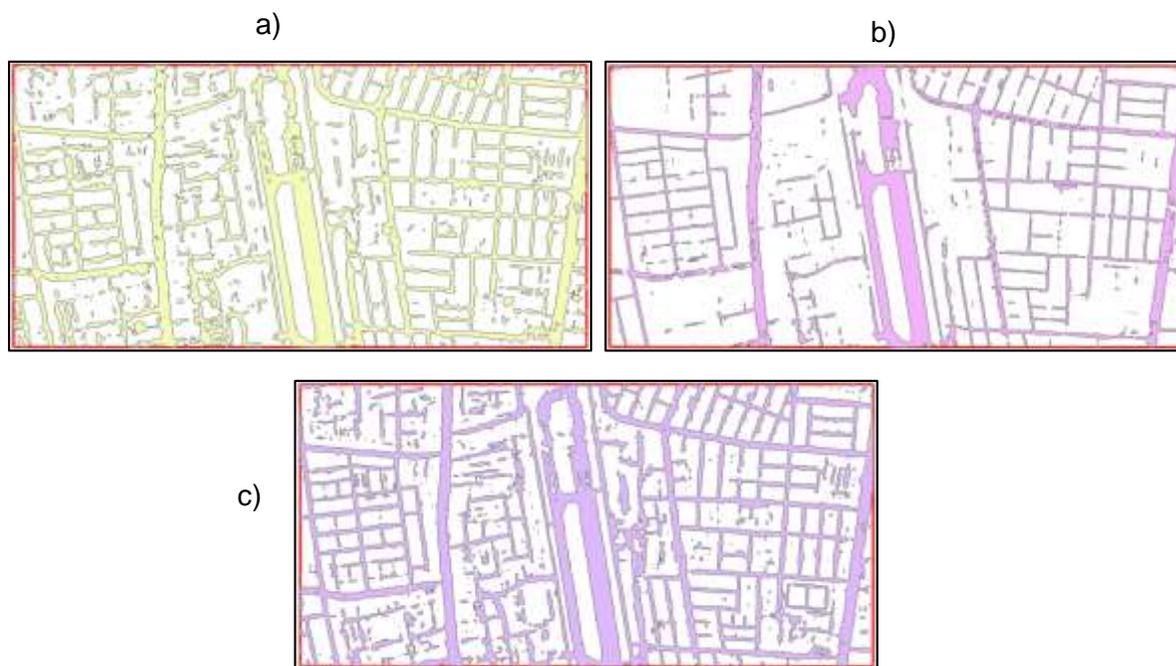
*Nota.* a) Generalización de datos con Modelo Unet y Backbone Model Resnet 34 con 100 épocas en los polígonos de edificaciones, b) Generalización de datos con Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de edificaciones, c)

Generalización de datos con Modelo Unet y Backbone Model Resnet 152 con 200 épocas en los polígonos de edificaciones, d) Generalización de datos con Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de edificaciones, e) Generalización de datos con Modelo Unet y Backbone Model Resnet 152 con 5 épocas en los polígonos de edificaciones

Como se puede observar, una vez realizada la generalización de la información, el modelo de la Figura 63b presenta una mejor visualización de los polígonos de edificaciones, este modelo necesitó de 45 épocas para que genere un buen aprendizaje, así también el modelo d también generó una buena extracción de información sin embargo en este modelo existen polígonos agrupados los cuales no permitirán distinguir entre las edificaciones, el modelo c con 5 épocas no dio buenos resultados, por lo que la visualización de edificaciones es muy escasa.

### Figura 64.

*Resultados del proceso de generalización para vías*



*Nota.* a) Generalización de datos con Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de vías, b) Generalización de datos con Modelo UNet y Backbone Model Resnet 152 con 200 épocas en los polígonos de vías, c) Generalización de datos con Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de vías

Como se puede observar, el modelo de la Figura 64c presenta una mejor visualización de los polígonos de vías, cabe recalcar que con este modelo se pudo obtener las vías de cuarto orden, a diferencia del modelo b en el cual solo se observan las vías de primer orden.

### Figura 65.

*Resultados del proceso de generalización para vías*



*Nota.* a) Generalización de datos con Modelo UNet y Backbone Model Resnet 34 con 200 épocas en los polígonos de manzanas, b) Generalización de datos con Modelo BDCN y Backbone Model Resnet 34 con 200 épocas en los polígonos de manzanas, c) Generalización de datos con Modelo UNet y Backbone Model Resnet 152 con 200 épocas en los polígonos de manzanas d) Generalización de datos con Modelo BDCN y Backbone Model Resnet 152 con 200 épocas en los polígonos de manzanas.

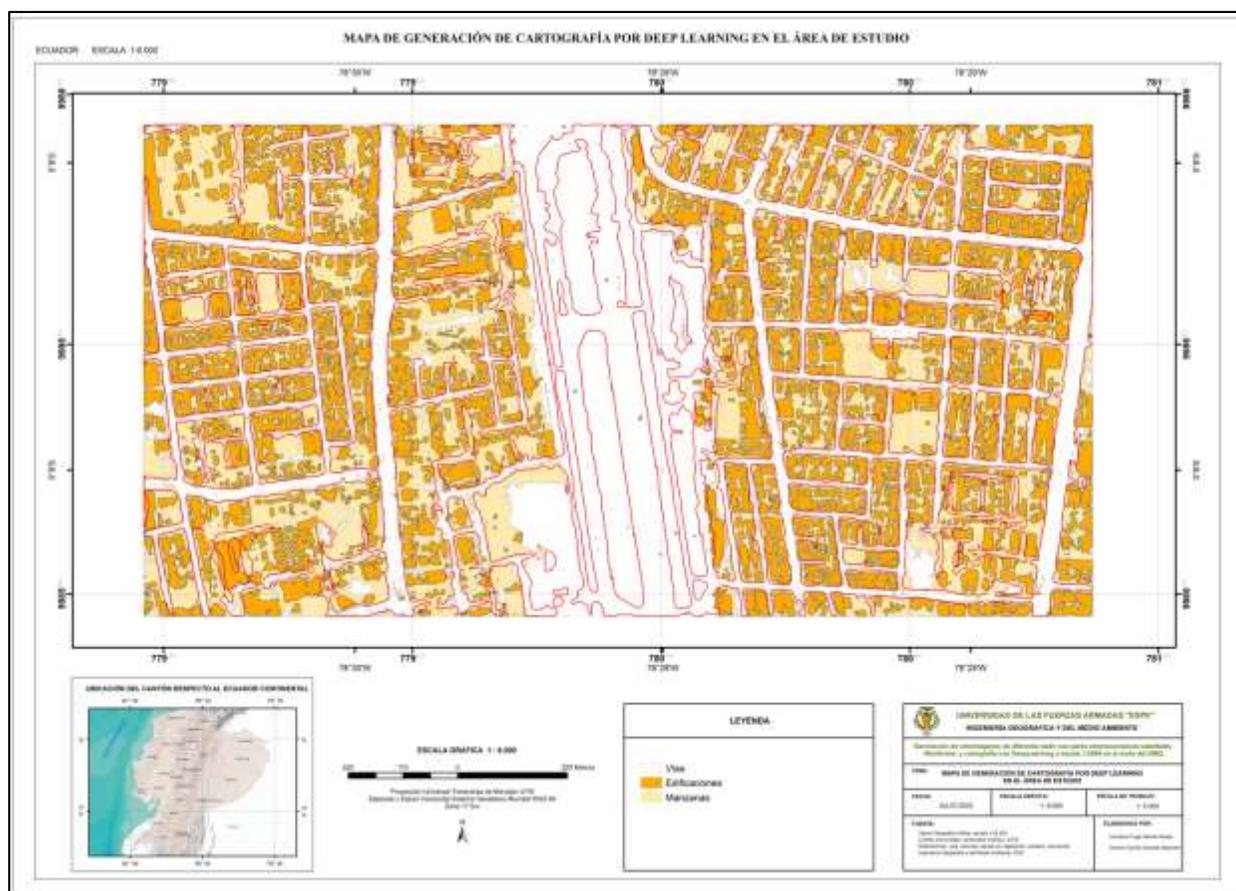
En el proceso de generalización de manzanas es indispensable que el producto no tenga huecos ya sean estos correspondientes a canchas o lotes baldíos, por lo que el modelo c con 27 épocas ha logrado disminuir el error con respecto a los huecos en los polígonos de manzanas, sin embargo en el modelo a se puede observar que la extracción de información también afectó a los parterre.

### **Resultado de la generación de cartografía por Deep Learning**

Una vez obtenidos los datos de clasificación y generalización es necesario generar topología en cada una de las entidades que se consideren más óptimas para el proceso de cartografía, ver Figura 66.

Figura 66.

Mapa de cartografía por Deep Learning



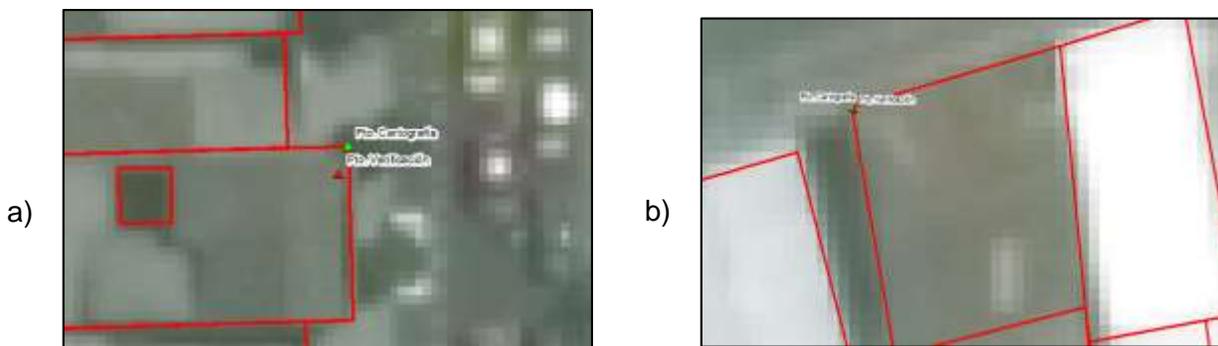
**Resultados de la exactitud espacial de los productos derivados de los procesos de digitalización y deep learning**

### ***Evaluación de exactitud posicional de la cartografía Digitalizada***

Dentro del análisis se tomaron 20 puntos de verificación para realizar la evaluación de la cartografía, en la Figura 67 se ejemplifica la distancia máxima y mínima que existe entre el punto de referencia y su homólogo en la cartografía digitalizada.

**Figura 67.**

*Desplazamiento del punto de referencia y homólogo en la cartografía digitalizada*



*Nota.* a) Distancia máxima: 1.43m; b) Distancia mínima: 0.134m

En la Tabla 42 se muestran los valores de los estadísticos media, desviación estándar, máximo y mínimo, también los estadísticos de la norma NSSDA y la norma IGM.

**Tabla 42.**

*Resultados exactitud posicional de la cartografía Digitalizada*

<b>Estadística</b>	<b>Digitalización</b>
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

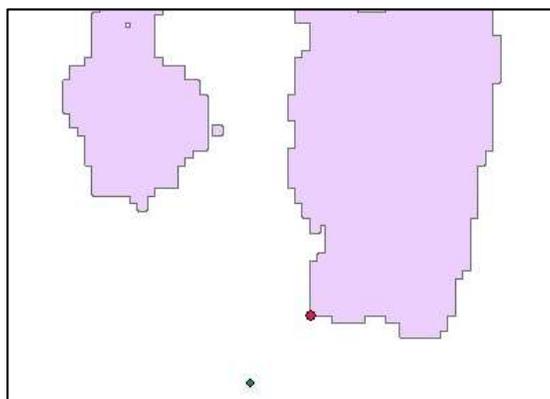
De acuerdo a los datos estadísticos analizados se menciona que la cartografía digitalizada de la ortoimagen de año 2014 de nadir  $13.1^\circ$  cumple con la norma NSSDA y normativa IGM, con valores de 1.444m y 1.266m respectivamente, puesto que no excede el valor en dirección horizontal de 1.5m admitido según la normativa IGM.

### ***Evaluación de exactitud posicional de la cartografía Deep Learning***

Dentro del análisis se utilizaron los 5 puntos de evaluación para la cartografía por deep learning, esto ya que el producto de la extracción por deep learning tuvo bastantes inconsistencias en los vértices, en la Figura 68 se observa la distancia mínima que existe entre el punto de referencia y su homólogo en la cartografía.

#### **Figura 68.**

*Desplazamiento del punto de referencia y homólogo en la cartografía por deep learning*



*Nota.* Distancia mínima: 1.87m

En la Tabla 43 se muestran los valores de los estadísticos media, desviación estándar, máximo y mínimo, también los estadísticos de la norma NSSDA y la norma IGM.

**Tabla 43.**

*Distancias mínimas del punto de referencia y homólogo en la cartografía por deep learning*

<b>Puntos</b>	<b>Distancias</b>
1	2.80
5	2.52
6	1.87
17	4.78
20	6.35

De acuerdo con las distancias obtenidas se menciona que la cartografía generada por deep learning de la ortoimagen del año 2014 de nadir 13.1° no cumple con la norma NSSDA y normativa IGM, debido a que posee con valores que exceden el valor en dirección horizontal de 1.5m admitido según la normativa IGM.

### **Resultados del control de calidad aplicando la Norma ISO 19157**

#### **Resultados de Control de Compleción**

En la Tabla 44, se muestran los resultados por cada cuadro de la verificación de omisiones y comisiones de cada una de las cartografías generadas.

**Tabla 44.***Resultados de control de compleción*

<b>Cuadro</b>	<b>Omisión digitalización</b>	<b>Comisión digitalización</b>	<b>Omisión Deep Learning</b>	<b>Comisión Deep Learning</b>
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
----	----	----	----	----

Como se muestra en la Tabla 44, la cartografía por digitalización no obtuvo comisiones (datos excedentes) ni omisiones (datos ausentes) en la base final. En la cartografía generada por Deep Learning se tienen omisiones debido a que no se pudo levantar objetos como arbol\_p, tierra\_sin\_vegetacion\_a, cancha\_a, parterre\_a y via\_ruta\_l; pero analizando los objetos que se pudieron levantar como edificio\_a, via\_ruta\_a y manzana\_a, se tienen omisiones y comisiones, con esto se puede decir: que no cumple con la norma ISO 19157, por tanto, no es posible levantar todos los objetos mediante esta técnica.

### Resultados de Control de Consistencia Lógica

En la Tabla 45, se muestran los resultados del control de consistencia lógica, en el que se comprueba el apego al catálogo de objetos a escala 1:5000 de cada uno de los feature class generados.

**Tabla 45.**

*Resultados de Control 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	-
------------	---	------------	---

*Nota:* Donde: “X” cumple con los atributos del catálogo de objetos; “-” no existe la capa.

Las capas de digitalización se apegan con los atributos presentes en el catálogo de objetos. En la cartografía generada por Deep Learning no se levantó la información de las capas: tierra\_sin\_vegetacion\_a, arbol\_p, cancha\_a, parterre\_a y via\_ruta\_l, por lo que no están en la GDB.

### Resultados de Control de exactitud posicional

En la Tabla 46, se detallan los resultados obtenidos al aplicar las normas NSSDA e IGM a la cartografía generadas por digitalización.

**Tabla 46.**

*Resultados exactitud posicional de la cartografía*

Estadística	Digitalización
Dist. Min (m)	0.134
Dist. Max (m)	1.430
Dist. Prom (m)	0.773
Desv. Est. (m)	0.334
RMSE <sub>x</sub> (m)	0.562
RMSE <sub>y</sub> (m)	0.618
RMSE <sub>r</sub> (m)	0.835
Exactitud NSSDA r al 95% (m)	1.444

---

Exactitud IGM r al	1.266
90% (m)	

---

En la Tabla 47, se detallan los resultados obtenidos de exactitud posicional planimétrica para ortoimágenes y altimétrica en MDS.

Tabla 47.

*Resultados exactitud posicional planimétrica para ortoimágenes y altimétrica en Modelos Digitales de Superficie*

Años	Ortoimágenes														
	2014 (100km <sup>2</sup> )					2016 (25km <sup>2</sup> )					2018 (25km <sup>2</sup> )				
# 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 <sub>x</sub> [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 <sub>y</sub> [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 <sub>z</sub> [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
<b>Modelos Digitales de Superficie</b>															
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

## Capítulo V

### Conclusiones y Recomendaciones

En este capítulo se detallan las conclusiones y recomendaciones de todo el trabajo.

#### Conclusiones

Se cumplieron con todos los objetivos y metas del proyecto de titulación, además dicha investigación servirá de aporte para profesionales y estudiantes interesados en el geoprocesamiento de ortoimágenes de pares estereoscópicos de alta resolución y en la generación de cartografía mediante Deep Learning.

Luego de experimentar y ortorrectificar las imágenes satelitales de pares estereoscópicos con diferente nadir a partir de LPS Core (ERDAS Imagine) utilizando los métodos Polynomial Based Pushbroom y los Coeficientes Polinomiales Racionales (RPC) en las aerotriangulaciones, se concluye que con el método RPC con 42, 30, 21, 9 y 7 GCP 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 100km<sup>2</sup> y 25km<sup>2</sup>, 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, con resoluciones espaciales de 0.40m y 0.50m, con nadir de 13.1° y 26.0°, con un área de 100km<sup>2</sup> y 25km<sup>2</sup> respectivamente, 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; mientras que, la ortoimagen del año 2018, con resolución espacial de 0.50m, nadir de 27.7° y un área de 25km<sup>2</sup>, no cumple con la escala de hipótesis y serviría para escala 1:7000 o menores. En cuanto a la precisión vertical de los MDS por correlación generados a

través del ajuste de las ortoimágenes, el producto 2016 cumple con un nivel de confianza del 95%; mientras que, los MDS de los años 2014 y 2018 superan en promedio los 1.5m.

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; al no poder generar objetos puntuales y lineales; por la cantidad de modelos de entrenamiento y que estos no pueden ser generalizados para toda la topografía del país; por los requerimientos de hardware y costos de software; entre otros, 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. Aun así, la cartografía automatizada con deep learning es muy útil en la extracción de vías de similar material y en manzanas cuando se aplican grandes muestras (en extensión) para el entrenamiento del modelo.

### **Recomendaciones**

Identificar la cobertura de telefonía a nivel nacional para utilizar el método NTRIP, ya que este método necesita anclarse a una red wi-fi, misma que puede ser compartida desde un teléfono móvil o una red wifi a la antena GNSS. Adicional utilizar diferentes métodos de navegación, para identificar los puntos de control terrestre, entre los que se puede destacar el uso de GPS móvil con archivo .gpx o el uso de google maps mediante un archivo .kml.

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.

Generar cartografías por los métodos: interpretación / digitalización y deep learning, en áreas mayores a 200ha y con ortoimágenes de nadir igual o inferior a 13.1°, para validarlas en base a la norma ISO 19157.

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.

En la herramienta Traing Deep Leaning Model, se recomienda una cantidad elevada de épocas y seleccionar la opción *Stop when model stops improving*, con la finalidad de que el proceso de entrenamiento se detenga una vez que el modelo ha dejado de aprender, lo cual evita pérdidas de tiempo y de memoria del equipo en el cual se esté desarrollando.

## Bibliografía

- Aduviri, G., Tito Loza, S., & Delgado, J. (2013). *Levantamiento planialtimétrico empleando la tecnología GNSS método cinemático en la localidad Caracollo Norte*. La Paz: Universidad Mayor de San Andrés.
- Agüero, E., Montilla, A., & Valero, G. (01 de 02 de 2018). *Medición de puntos GPS por el método estático con equipo diferencial. Una experiencia didáctica en el Instituto Pedagógico de Maturín*. Obtenido de <https://revistas.pedagogica.edu.co/>: <https://doi.org/10.17227/ted.num43-8655>
- Alonso, L., & Chaves, S. (2021). Uso de drones y sensores remotos para el monitoreo de laderas: una revisión. *Ingenierías USBMed*, 65-73.
- Altamirano, L. (2021). Deep Learning aplicado a la Segmentación Semántica de Imágenes aéreas. *Universidad de Valparaíso*, 1-57.
- Ariza, F. J., García, J. L., Rodríguez, J., & Robledo, J. (2019). *Guía para la evaluación de la exactitud posicional de datos espaciales*.
- ASPRS. (2013). ASPRS Accuracy Standards for Digital Geospatial Data. *Photogrammetric Engineering & Remote Sensing*, 1080.
- Avendaño, J., & Vásquez, J. (2017). *NIVELACIÓN GEOMETRICA DE POLIGONAL CHOCONTA-SUESCA (APOYO AL PROYECTO DE INVESTIGACIÓN SOBRE PLANOS TOPOGRAFICOS LOCALES -TRAMO k11+000 al k14+000)*. Bogotá: Universidad Distrital Francisco José de Caldas .
- Baatz, M., Benz, U., Dehghani, S., & Heynen, M. H. (2004). Ecognition professional: user guide. *Munih Definiens Imaging*, 4:486.
- Baluyan, H., Joshi, B., Hinai, A., & Woon, W. (2013). Novel Approach for Rooftop Detection Using Support Vector Machine. *ISRN Machine Vision*, 1-11.
- Barragán, W., Martínez, A., & Garzón, P. (2015). Generación automática de cartografía para edificaciones, utilizando fotografías digitales aéreas verticales de alta resolución espacial y nubes de puntos LiDAR. *Revista de ingeniería*(42), 30-38.
- Barros, S., & Agudelo, L. (2015). IMPLEMENTACIÓN DE UN ALGORITMO DE CORRESPONDENCIA ENTRE PÍXELES EMPLEANDO GEOMETRÍA EPIPOLAR, PARA APLICACIONES DE VISIÓN ESTEREOSCÓPICA. Medellín: Universidad de San Buenaventura Seccional. Obtenido de [http://bibliotecadigital.usbcali.edu.co/bitstream/10819/3287/1/Implementacion\\_Algoritmo\\_Correspondencia\\_Barros\\_2015.pdf](http://bibliotecadigital.usbcali.edu.co/bitstream/10819/3287/1/Implementacion_Algoritmo_Correspondencia_Barros_2015.pdf)
- Basu, S., Ganguly, S., Mukhopadhyay, S., Dibiano, R., Karki, M., & Nemani, R. (2015). DeepSat: a learning framework for satellite imagery. *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems - GIS*, 1-10.

- Batista, P., & Ferman, O. (2018). Los descriptores de la cartografía temática satelital para la gestión de emergencias pos desastres: caso inundaciones. *Revista Ciencia y Tecnología*, 143-157.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35-43.
- Bravo, J. D. (2000). Breve introducción a la cartografía ya los sistemas de información geográfica (SIG). CIEMAT.
- Briceño, A. (2009). Observaciones GPS NTRIP : Una nueva alternativa para el posicionamiento preciso en Venezuela. *Rev. Tec. En g. Universidad Zulia*, 2-8.
- Büyüksalih, G., & Jacobsen, K. (2013). Comparison of DEM Generation by Very High Resolution Optical Satellites. *New Developments and Challenges in Remote Sensing*, 627-637.
- Camisay, M. F., Mackern, M. V., & Calori, A. V. (2013). Posicionamiento RT-NTRIP, una alternativa rápida y segura para la vinculación con los marcos de referencia. Universidad Juan Agustín Maza.
- Campos, A. (2021). Construcción de un catastro solar mediante uso de drones y herramientas SIG: caso de estudio municipio El Retiro, Antioquia. 80-94.
- Cañizares, E., Tierra, A., & Leiva, C. (2015). Sistema de Alturas para el Ecuador. X CONGRESO DE CIENCIAS Y TECNOLOGÍA ESPE 2015, (págs. 88-93). Sangolqui .
- Cappellotto, L., Acosta, A., Pérez, D., Orgeira, M., & Gómez, D. (2020). Determinación de alta precisión de la altura del nivel del mar alcanzada por la ingresión Belgranense para el sector norte de Buenos Aires y sur de Santa Fe y Entre Ríos. *Revista de la Asociación Geológica Argentina*, 132-143.
- Catalá, L. (2021). Segmentación y reconstrucción de escenas de tráfico mediante Deep Learning. *Universidad de Alicante*, 1-67.
- Cheng, G., Han, J., & Lu, X. (2017). Remote sensing image scene classification: benchmark and state of the art. *Proceedings of the IEEE*, 1865-1883.
- Chinchilla, R., & Morales, F. (1998). Programación orientada a objetos usando JAVA. *Revista de Bibliotecología y Ciencias de la Información*, 9-12.
- Chuvieco, E. (2010). *Teledetección ambiental: La observación de la tierra desde el espacio*. Bogotá: Ariel.
- Cisneros, S., García, É., Montoya, K., & Sinde, Í. (2019). Estudio de las configuraciones de puntos de control terrestre para fotogrametría con drone. *Revista Geoespacial*, 43-57.
- Cmisay, M., Mackern, M., & Calori, A. (2013). Posicionamiento RT-NTRIP, una alternativa rápida y segura para la vinculación con los marcos de referencia. *IV Jornadas de Investigación 2013 - Universidad Juan Agustín Maza* (págs. 1-2). Mendoza: Universidad Juan Agustín Maza.
- Codazzi, I. G. (2016). *Especificaciones técnicas Cartografía Basica Didital*. Colombia.

- Cogliano, D. D. (2006). *Modelado del Geoide con GPS y Gravimetría Caracterización de la Estructura Geológica de Tandil*. Rosario, Argentina.
- Cuentas, N., Yáñez, L., & Faure, J. (2017). Modelado del Cuasi-Geoide a partir de nivelación geométrica, gravimetría y posicionamiento satelital. *UDELAR*, 31-37. Obtenido de UDELAR Instituto de Agrimensura:  
<https://www.colibri.udelar.edu.uy/jspui/bitstream/20.500.12008/22860/1/CY19.pdf>
- Cunha, A., Lani, J., Amaral, E., Rezende, S., & Ribeiro, L. (s.f.). Mosaico digital de aerofotos no convencionales en la evaluación de los recursos naturales: estudio de caso. *Revista Brasileña de Ingeniería Agrícola y Ambiental*, 182-187.
- Díaz, O. (10 de noviembre de 2018). *Impacto del procesamiento de una imagen satelital de alta resolución en su precisión horizontal*. Obtenido de  
<https://www.linkedin.com/pulse/impacto-del-procesamiento-de-una-imagen-satelital-en-diaz-bocanegra/>
- DigitalGlobe. (2014). *Worldview 2 data sheet*. Obtenido de  
<https://www.spaceimagingme.com/downloads/sensors/datasheets/WorldView2-DS-WV2-Web.pdf>
- DigitalGlobe. (21 de Abril de 2021). *About DigitalGlobe*. Obtenido de MAXAR:  
<https://www.digitalglobe.com/company/about-us/>
- DiMarzio, J. (2016). *Beginning Android Programming with Android Studio*. John Wiley & Sons, Inc.
- Echevarría, M. F. (2019). Determinación de un Modelo de Geoide local para la ciudad de Bahía Blanca. 13. Obtenido de  
<http://www.bibliotecacpa.org.ar/greenstone/collect/facagr/index/assoc/HASH01a3.dir/doc.pdf>
- Enríquez, D., Leiva, C., Cárdenas, S., Sánchez, J., & Toulkeridis, T. (2021). Validation of the GPS leveling method through the gradient analysis of the geoidal wave. Case study of Ecuador. *Revista Geografica Venezolana*, 62, 316-329. doi:10.53766/RGV/2021.62.2.02
- Espinosa, I. (2009). *ANÁLISIS DE LOS MODELOS EGM08, KMS02 Y DTMECU PARA EL CÁLCULO DEL GEOIDE GRAVIMÉTRICO LOCAL DE LA ZONA COMPRENDIDA ENTRE LAS LATITUDES 1°S Y 2°S Y ENTRE LAS LONGITUDES 81°W Y 78°W*. Sangolqui, Pichincha, Ecuador.
- ESRI. (2016). *Reglas topológicas de las geodatabases y soluciones a los errores de topología*. Obtenido de <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/editing-topology/geodatabase-topology-rules-and-topology-error-fixes.htm>
- ESRI. (2019). *ArcGIS Desktop*. Obtenido de Una vista general de las herramientas de Generalización: <https://desktop.arcgis.com/es/arcmap/10.7/tools/cartography-toolbox/an-overview-of-the-generalization-toolset.htm>
- ESRI. (2022). *ArcGIS PRO*. Obtenido de ArcGIS Pro 3.0 system requirements: <https://pro.arcgis.com/en/pro-app/latest/get-started/arcgis-pro-system-requirements.htm>

- ESRI. (2022). *Edge Detection with arcgis.learn*. Obtenido de ArcGIS API for Python: <https://developers.arcgis.com/python/guide/edge-detection-with-arcgis-learn/#bi-directional-cascade-network-for-perceptual-edge-detection-bdcn>
- ESRI. (2022). *How U-net works?* Obtenido de ArcGIS API for Python: <https://developers.arcgis.com/python/guide/how-unet-works/>
- Fernández, I. (2001). *Localización Geográfica* (4 ed.). Valladolid, España.
- FGDC. (1998). Geospatial Positioning Accuracy Standards Part 3: National Standard for Spatial Data Accuracy. En *National Aeronautics and Space Administration*. Virginia, NV, USA. Obtenido de <https://www.fgdc.gov/standards/projects/FGDC-standards-projects/accuracy/part3/chapter3>
- Flóres, H. A. (2012). Programación orientada a objetos usando JAVA. ECOE.
- Flores, J., Bustamante, Á., Vargas, S., Cajuste, L., Escobedo, F., & Valadez, M. (2020). Cartografía del uso del suelo en la subcuenca Huaquechula, Puebla, México, con un índice combinado de imágenes de satélite. *Investigaciones geográficas*.
- Fuentes, J. (2020). Comparación de modelos de altura de la vegetación para estimación de biomasa en un bosque de manglar en el Caribe Colombiano. *Entorno geográfico*, 1-18.
- Furones, Á. (2011). *SISTEMA Y MARCO DE REFERENCIA TERRESTRE. SISTEMAS DE COORDENADAS*. Valencia, España.
- Garay, D. (2020). Incendios rurales y forestales: La importancia de la Teledección y los Sistemas de información Geográfica. *Tecnoárido*, 45-48.
- García, J.-A. (2022). De la topología a la geometría: implementación de mapas mentales a los Sistemas de Información Geográfica. *Revista de la Universidad de Granada*, 88-107.
- Gehrig, S., Schneider, N., Stalder, R., & Franke, U. (2017). Stereo vision during adverse weather — Using priors to increase robustness in real-time stereo vision. *Image and Vision Computing journal*, 12.
- Gers, J., & Cardona, R. (s.f.). Uso de la información del GIS en el análisis de los yacimientos petrolíferos. *Dyra Ingeniería e industria*, 1-7.
- Gong, K., & Fritsch, D. (2019). DSM Generation from High Resolution Multi-View Stereo Satellite Imagery. *Photogrammetry and Remote Sensing*, 379-387.
- González, P. (22 de 05 de 2015). *Levantamiento mediante GPS de una red de puntos establecidos para correlacionar los distintos espacios de la universidad en el mismo sistema de coordenadas*. Obtenido de Universidad Politécnica de Cartagena: <https://repositorio.upct.es/handle/10317/4651>
- Guevara, C., Lara, B., & Vives, L. (2018). Una metodología para la caracterización del uso del suelo mediante imágenes de media resolución espacial. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 207-2018.

- Guinea, A. (2014). *Calidad de geo-procesos vs calidad de geo-datos*. Obtenido de [https://www.idee.es/resources/presentaciones/JIIDE14/20141107/Calidad-geoinformaci%C3%B3n\\_presentacion.pdf](https://www.idee.es/resources/presentaciones/JIIDE14/20141107/Calidad-geoinformaci%C3%B3n_presentacion.pdf)
- Hohensee, B. (2014). *Introducción A Android Studio. Incluye Proyectos Reales Y El Código Fuente*. Babelcube.Inc.
- Höhle, J. (2021). Automated mapping of buildings through classification of DSM-based ortho-images and cartographic enhancement. *International Journal of Applied Earth Observation and Geoinformation*.
- IGM. (2006). Especificaciones Técnicas Generales para la realización de Cartografía Topográfica a Cualquier Escala (Primer Borrador).
- IGM. (16 de Abril de 2008). *Instituto Geográfico Militar*. Obtenido de Especificaciones Técnicas para Ortofotos Digitales: [http://www.geoportaligm.gob.ec/portal/?wpfb\\_dl=43](http://www.geoportaligm.gob.ec/portal/?wpfb_dl=43)
- IGM. (2016). Especificaciones técnicas para la producción de cartografía escala 1:5 000. Quito, Ecuador: IGM.
- IGM. (2018). Protocolo de fiscalización para proyectos de generación de cartografía base con fines catastrales escala 1:1000, obtenida a través del método aerofotogramétrico, digitalización 2D sobre ortofoto o levantamiento topográfico. 11.
- IGM. (2020). Especificaciones técnicas para el control de la exactitud posicional en cartografía y ortofoto.
- IGM. (2020). *Resolución Nro. IGM-IGM-2020-0095-R*. Quito, Ecuador. Obtenido de <http://www.geoportaligm.gob.ec/geodesia/wp-content/uploads/2020/10/IGM-IGM-2020-0095-R.pdf>
- IGM. (09 de 11 de 2021). *INFORME TECNICO PARA LA ADOPCION DEL MARCO GEODESICO DE REFERENCIA NACIONAL*. Obtenido de SNI: [https://sni.gob.ec/documents/10180/3346059/2+InfTec\\_Adopcion+Marco+Geod%C3%A9sico+Referencia+SIRGAS.pdf/d90747c2-2990-48bd-8691-b2de631af4c1](https://sni.gob.ec/documents/10180/3346059/2+InfTec_Adopcion+Marco+Geod%C3%A9sico+Referencia+SIRGAS.pdf/d90747c2-2990-48bd-8691-b2de631af4c1)
- IGM. (2021). *NTRIP IGM*. Obtenido de <http://www.geoportaligm.gob.ec/ntrip/public/register>
- IGN. (2019). Introducción a RAMSAC NTRIP. IGN.
- INSTITUTO GEOGRÁFICO MILITAR. (06 de 2020). *GEOPORTAL IGM*. Obtenido de [http://www.geoportaligm.gob.ec/wordpress/?page\\_id=32](http://www.geoportaligm.gob.ec/wordpress/?page_id=32)
- Instituto Geográfico Militar. (s.f.). *Red GNSS de Monitoreo Continuo del Ecuador – REGME*. Obtenido de IGM: <http://www.geograficomilitar.gob.ec/red-gnss-de-monitoreo-continuo-del-ecuador-regme/>
- Intracaso, A. (2006). Boletín del Instituto de Fisiografía y Geología. 1, 18.
- Jain, K., Singh, H., Singh, K., & Malhi, A. (2017). Efficient disparity estimation from stereo images using hybrid-guided image filter. *The Imaging Science Journal*.
- Jarandilla, V. (2014). RESTITUCIÓN FOTOGRAFÍCA DIGITAL PARA LA GENERACIÓN DE UN MAPA FISIOGRAFÍCA Y USO ACTUAL DE LA TIERRA. La Paz, Bolivia:

- Universidad Mayor de San Andrés. Obtenido de <https://repositorio.umsa.bo/xmlui/bitstream/handle/123456789/9578/PG-1358-Jarandilla%20Altuzarra%2C%20Vladimir.pdf?sequence=1&isAllowed=y>
- Jorge Moya; Bepsy Cedeño. (2017). CONCEPTOS BÁSICOS EN GEODESIA COMO INSUMO PARA UN TRATAMIENTO ADECUADO DE LA INFORMACIÓN GEOESPACIAL. *Revista Geográfica de América Central*, 1(58), 52-53.  
doi:<https://doi.org/10.15359/rgac.58-1.3>
- Kassas, Z., Neinavaie, M., Khalife, J., Khairallah, N., Kozhaya, S., Haidar, J., & Shadram, Z. (2021). Enter LEO on the GNSS Stage Navigation with Starlink Satellites. *Engineering Solutions from the Global Navigation Satellite System Community*, 1-12.
- Kugler, T., & Went, L. (2021). Evaluation of Digital Elevation Models Derived from Multi-Date Satellite Stereo Imagery for Urban Areas. *GI-Forum*, 60-67.
- Kumar, J., & Da Silva, I. (2018). *Applications of Geomatics in Civil Engineering*. Singapur: Springer Nature Singapore.
- Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.
- Lagos, M. (2010). *Generalización cartográfica*. Colombia: Editoriales Universitarias de Colombia (ASEUC).
- Leiva, C. (2010). *IGM*. Obtenido de SENPLADES: <https://slideplayer.es/slide/3016024/>
- Leiva, C. (2014). Determinación de modelos de predicción espacial de la variable de ondulación geoidal, para la zona urbana del cantón Quito y la zona rural del cantón Guayaquil, utilizando técnicas geoestadísticas. 8-37.
- Leiva, C., Araujo, N., & Bueñaño, X. (2017). MODELO DE PREDICCIÓN ESPACIAL DE ONDULACIÓN GEOIDAL, PARA EL ÁREA URBANA DE QUITO, UTILIZANDO TÉCNICAS GEOESTADÍSTICAS. *GEOESPACIAL*(14), 84-88.
- Li, D., & Dong, Y. (2014). Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 197-387.
- Lind, D., Marchal, W., & Wathen, S. (2012). *Estadística aplicada a los negocios y la economía*. México D.F: Mc Graw Hill.
- Lobaina, A. A., Beatón, D. M., & Fuentes, C. G. (2014). *Contribución al método de interpolación con triangulación de Delaunay* (Vol. 30). Cuba. Obtenido de <https://www.redalyc.org/pdf/2235/223531569004.pdf>
- López, A. (03 de 2021). *Evaluación del desempeño del método de nivelación Trigonométrico por visuales recíprocas y simultáneas, en la red altimétrica de la ciudad de los Ángeles*. Obtenido de Biblioteca UdeC Repositorio: <http://repositorio.udec.cl/bitstream/11594/7938/1/Evaluaci%c3%b3n%20del%20desempe%c3%b1o%20del%20m%c3%a9todo%20de%20nivelaci%c3%b3n.....pdf>

- López, E., Abascal, R., & Zepeda, S. (2018). Extracción automática de la vegetación en la zona metropolitana de la Ciudad de México utilizando procesamiento morfológico. *Pistas educativas*.
- Lopez, E., Núñez, A., & Gómez, C. (2010). *TEST DE ANÁLISIS DE LA PRECISIÓN EN DETERMINACIÓN*. Barcelona: EPSEB.
- Lopez, S. (1996). *Topografía* (Segunda ed.). Madrid, España.
- Martín, A. (Agosto de 2020). 4-SISTEMAS DE REFERENCIA GEODESICOS. 41. Obtenido de [https://www.researchgate.net/publication/343627274\\_4-SISTEMAS\\_DE\\_REFERENCIA\\_GEODESICOS](https://www.researchgate.net/publication/343627274_4-SISTEMAS_DE_REFERENCIA_GEODESICOS)
- MAXAR. (Agosto de 2020). *Worldview 3*. Obtenido de MXR-DS-WV3: [https://cdn1-originals.webdamdb.com/13264\\_95553821\\_2?Policy=eyJTdGF0ZW1lbnQiOiI7IjIc291cmNlIjoiaHR0cCo6Ly9jZG4xLW9yaWdpbmFscy53ZWJkYW1kYi5jb20vMTMyNjRfOTU1NTM4MjFmMlslkNvbmlRpdGlvbil6eyJEYXRITGVzc1RoYW4iOnsiQVdTOKVwb2NoVGltZSI6MjE0NzQxNDQwMH19fV19&Signat](https://cdn1-originals.webdamdb.com/13264_95553821_2?Policy=eyJTdGF0ZW1lbnQiOiI7IjIc291cmNlIjoiaHR0cCo6Ly9jZG4xLW9yaWdpbmFscy53ZWJkYW1kYi5jb20vMTMyNjRfOTU1NTM4MjFmMlslkNvbmlRpdGlvbil6eyJEYXRITGVzc1RoYW4iOnsiQVdTOKVwb2NoVGltZSI6MjE0NzQxNDQwMH19fV19&Signat)
- MAXAR. (s.f.). Imagery Support Data (ISD) Documentation.
- Mazón, B., Joffre, C., Víctor, C., & Wilmer, R. (2015). Fundamentos de programación orientada a objetos en JAVA. Machala: Universidad Técnica de Machala.
- Moncada, J. (2018). La cartografía de los ingenieros militares. Instrumento para el conocimiento del territorio. *Revista de geografía Norte Grande*.
- Moreira, L. A., & Krueger, C. P. (2020). Análise de precisão e acurácia de métodos de posicionamento em tempo real na determinação de desníveis. *Revista Brasileira de Geomatica*, 8(1). doi:10.3895/rbgeo.v8n1.9843
- Morell, S., Frasquet, M., & Estornell, J. (2022). Cartografía del abandono de cultivos de cítricos mediante el uso de datos altimétricos: LiDAR y fotogrametría SfM. *Revista de Teledetección*, 49-60.
- Neira, R. (2005). Fotografía Aérea. Valdivia: Universidad Austral de Chile. Obtenido de <http://cybertesis.uach.cl/tesis/uach/2005/bmfcin415f/doc/bmfcin415f.pdf>
- Neuman, K., Zapperi, P., Aldalur, B., Campo, A., Bongiovanni, A., & Pischel, D. (2018). Modelo digital del terreno mediante relevamientos con GNSS. *Geografía y Sistemas de Información Geográfica (GEOSIG)*, 107-117.
- NGA. (15 de 01 de 2022). *OFFICE OF GEOMATICS*. Obtenido de Earth Gravitational Model 2008 (EGM2008) Data and Apps: <https://earth-info.nga.mil/>
- Novo, A., Rodríguez, J., Acuña, C., Álvarez, X., & Lorenzo, H. (2021). Teledetección y Sistemas de Información Geográfica en el ámbito forestal. *VIII Jornadas Iberoamericanas de Innovación Educativa en el Ámbito de las TIC y las TAC Las Palmas de Gran Canaria, 18 y 19 de noviembre de 2021*, 201-208.
- Olaya, V. (2014). *Sistemas de Información Geográfica*. 854. (ICOG, Ed.) España.

- Palacios, I., & Arellano, K. (2022). Obtención de alturas niveladas mediante nivelación GPS  
Caso de estudio: Morona – Ecuador. *Revista Uniciencia*, 1-13.
- Paz, F., Castillo, E., Cabrera, J., & Medrano, E. (2018). Base de datos nacional de índices de  
vegetación: Resolución espacial de 250m y resolución temporal de 10 días. *Elementos  
para políticas públicas*, 109-124.
- Pelton, J., Madry, S., & Camacho-Lara, S. (2017). Handbook of satellite applications. *Springer  
Publishing Company*.
- Peñafiel, J., & Zayas, J. (2001). FUNDAMENTOS DEL SISTEMA GPS. *COLEGIO OFICIAL DE  
INGENIEROS TECNICOS EN TOPOGRAFIA*, 68-86.
- Pérez, C., & Muñoz, A. (2006). *Teledetección: Nociones y aplicaciones*. Salamanca:  
Universidad de Salamanca.
- Pérez, M. (2018). Análisis multitemporal de la zona de explotación minera a cielo abierto en el  
municipio de Duitama a partir de imágenes Landsat 7 y Sentinel 2A. *Universidad militar  
Nueva Granada*, 1-9.
- Pino, E., & Huayna, G. (2022). Spatial and temporal evolution of olive cultivation due to pest  
attack, using remote sensing and satellite image processing. *Scientia Agropecuaria*,  
149-157.
- Posada, J. (2013). *Fotogrametría Básica: Cálculo de la escala y el paralaje*. Obtenido de  
Introducción a las TIGs: [https://titulaciongeografia-  
sevilla.es/contenidos/profesores/materiales/archivos/2013-12-  
185\\_FOTOGAMETRIA.pdf](https://titulaciongeografia-sevilla.es/contenidos/profesores/materiales/archivos/2013-12-185_FOTOGAMETRIA.pdf)
- Quintana, C., Lillo, M., Barrera, & J. (2012). Metodología para estimación de la turbidez de un  
lago mediante la clasificación. *Tecnología y ciencias del agua*.
- Quirós, E., & Cuartero, A. (2005). Posibilidades estereoscópicas de los datos espaciales.  
*Revista Internacional de Ciencia y Tecnología de la Información Geográfica*(5), 65-76.
- Ramos, A., Jimenez, R., Bernal, R., & Sánchez, G. (2019). Propuesta metodológica para la  
generación de ortofotos y modelos digitales de elevación de alta resolución a través de  
vuelos con drones no fotogramétricos. *Researchgate*, 1-7.
- Rapp, R. H. (1991). *GEODESIA GEOMÉTRICA*. 3.
- Recio, A. (2019). Procedimiento para la actualización del catastro minero utilizando las  
imágenes satelitales y la tableta electrónica. *Instituto Federal de Educacao Ciencia e  
Tecnologia do Rio Grande do Norte*, 1-17.
- Rey, J. F. (1999). *Nociones de Topografía, Geodesia y Cartografía*. Caceres.
- Rojas, D. (2018). Análisis multitemporal mediante imágenes landsat del cambio de la cobertura  
vegetal y su impacto en la desecación del espejo de agua en la laguna de Tota para el  
periodo de 1991 al 2017. *Universidad militar Nueva Granada*, 1-13.

- Roman-Gonzales, A., & Vargas-Cuentas, N. I. (2013). Análisis de imágenes hiperespectrales. *Revista Ingeniería & Desarrollo*, 9(35), 14-17. Obtenido de <https://hal.archives-ouvertes.fr/hal-00935014/document>
- Rosas, P. (05 de 2020). ADOPCIÓN DEL NUEVO MARCO GEODÉSICO DE REFERENCIA PARA EL ECUADOR (SIRGAS-ECUADOR). 22-34. Quito, Pichincha, Ecuador.
- Ruiz, A. M., García, J. L., & Mesa, J. L. (2010). ERROR, INCERTIDUMBRE, PRECISIÓN Y EXACTITUD, TÉRMINOS ASOCIADOS A LA CALIDAD ESPACIAL DEL DATO GEOGRÁFICO. Universidad de Jaén.
- Sáenz de la Pascua, A. (2019). Deep learning para el reconocimiento facial de emociones básicas. *Universidad politécnica de Catalunya*, 1-63.
- Sánchez, D., & Cano, N. (2014). Introducción A La Programación. Chía: IE San Josemaria Escrivá De Balaguer.
- Sanchez, E. (2017). *INFORME DE PASANTIA, NIVELACIÓN GEOMETRICA PARA LA GENERACIÓN DE UN MODELO GEOIDAL LOCAL EN LA EMPRESA ECOMPASS SAS*. Bogota.
- Sánchez, J. L. (2013). *Generación de una malla de ondulaciones geoidales por el método GPS/nivelación y redes neuronales artificiales a partir de datos dispersos*. La Plata, Argentina: Universidad Nacional de La Plata. doi:<https://doi.org/10.35537/10915/29002>
- Sánchez, L. (2002). DETERMINACIÓN DE ALTURAS FÍSICAS EN COLOMBIA. 6.
- Santecchia, G., & Span, J. (2020). Técnicas de posicionamiento GNSS aplicadas a la ingeniería. *MAPPING*, 3-4.
- Satellite Imaging Corporation. (2017). *WorldView-2 Satellite Sensor*. Obtenido de <https://www.satimagingcorp.com/satellite-sensors/worldview-2/>
- Satellite Imaging Corporation. (2018). *WorldView-3 Satellite Sensor*. Obtenido de <https://www.satimagingcorp.com/satellite-sensors/worldview-3/>
- SEAS. (17 de 07 de 2019). *BlogSEAS*. Obtenido de Conoce el lenguaje de programación Java: <https://www.seas.es/blog/informatica/conoce-el-lenguaje-de-programacion-java/#:~:text=Java%20es%20una%20plataforma%20inform%C3%A1tica,pudiese%20ejecutarse%20en%20cualquier%20dispositivo.>
- Seeber, G. (2003). *Satellite Geodesy* (Segunda ed.). Hannover, Alemania.
- Sefercik, U. G., Alkan, M., Atalay, C., Jacobsen, K., Büyüksalih, G., & Karakiş, S. (2020). Optimizing the Achievable Information Content Extraction from WorldView-4 Stereo Imagery. *PFG–Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 88(6), 449-461. doi:<https://doi.org/10.1007/s41064-020-00127-8>
- Segura, & Sanchis. (2018). Estrechamiento de cauces y cambio de patrón en cursos fluviales mediterráneos como consecuencia del cambio global en las últimas seis décadas: indicadores geomorfológicos. *Universitat de les Illes Balears, Sociedad Española de Geomorfología*, 396-398.

- Shaker, A., Yeing, W., & Easa, S. (2014). Using Stereo Satellite Imagery for Topographic and Transportation Applications: An Accuracy Assessment. *GIScience & Remote Sensing*, 321 - 337.
- Sharawi, A. (2021). Mapping from Fused High Resolution Satellites Stereo Imageries. *Photogrammetry and Remote Sensing*, 1-13.
- Silva, N. S., Rodino, R. P., & Peláez, R. Y. (2013). Red de transporte de datos en formato RTCM, vía protocolo de Internet (Ntrip). Implementación en la región y proyección futura a través de SIRGAS. *Revista Cartográfica*(89), 165-187.
- SIRGAS. (Abril de 2018). *Sistema de Referencia Geocéntrico para las Américas*. Obtenido de <https://www.sirgas.org/es/sirgas-rt/>
- Sisti, J., & Soto, L. (2018). Modelo Digital de Elevaciones (D.E.M.) Área Sierra El Gigante (Prov. San Luis), Densificación a Partir de Datos de Restitución Aerofotogramétrica. *Encuentro nacional de investigadores de agrimensura*, 1-8.
- Tierra, A. (2009). EVALUACIÓN DEL EGM08 Y EGM96 EN EL ECUADOR A PARTIR DE DATOS DE GPS Y NIVELACIÓN GEOMÉTRICA. *Revista Geoespacial*, 6, 53.
- Tierra, A., & Acurio, V. (2016). MODELO NEURONAL PARA LA PREDICCIÓN DE LA ALTURA GEOIDAL LOCAL EN EL ECUADOR. *REVISTA GEOESPACIAL*, 13(1), 59-72. Obtenido de <http://geoespacial.espe.edu.ec/wp-content/uploads/2017/01/Geoespacial13.1.pdf#page=66>
- Tierra, A., Silva, O., & Leiva, C. (2015). Correcciones diferenciales vía NTRIP para dispositivo móvil con aplicación android. *Scielo*.
- Torrent, E., Muñoz, Á., González, D., & Rodríguez, P. (2021). Implementación de procesos de control de calidad en la actualización de series cartográficas urbanas mediante combinación de CAD y SIG. *Revista cartográfica de de la Comisión de Cartografía del Instituto Panamericano de Geografía e Historia* .
- Torres, B., & Dubovik, O. (2018). Sensitivity tendencies in remote sensing of atmospheric aerosols. *EGU General Assembly Conference Abstracts*, 13181.
- Uribe, S. (2018). Generación de trayectoria de un objeto en un entorno 3D mediante visión artificial. *Universidad del País Vasco*.
- Vaní, P., Santos, M., Tenzer, R., & Hernández, A. (2003). *Algunos Aspectos Sobre Alturas Ortométricas y Normales*.
- Váscones, R., & Pila, A. (2017). Evaluation of Noise Pollution in Urban Touristic and Entertainment Zones. Case Study: La Mariscal parish, Quito-Ecuador. Evaluación de la Contaminación Acústica en Sectores Urbanos Turísticos y de Entretenimiento. Caso de Estudio: parroquia La Mariscal. *Instituto Nacional de Eficiencia Energética y energías renovables*, 126-134.
- Vértice. (2009). *Diseño Básico de Páginas Web en HTML*. Málaga: Editorial Vértice.
- Villalba, N. (2015). *Topografía Aplicada* . Lima: Macro.

- Wang, J., & Zhou, J. (2018). Band Weighting Network for Hyperspectral Image Classification. *Digital Image Computing: Techniques and Applications (DICTA)*, 1-8.
- Wang, Y., & Wang, X. (2019). An improved two-point calibration method for stereo vision with rotating cameras in large FOV. *Journal of Modern Optics*, 1106 - 1115.
- Zabala, M. (2018). Implementación del caster experimental para la distribución de medidas de GPS en tiempo real a través de NTRIP. *Revista del Instituto Panamericano de Geografía e Historia es un Organismo Especializado de la Organización de los Estados Americanos*, 117-120.
- Zabala, M., López, F., & Ortega, Á. (2017). Análisis e implementación de diferencial GPS en configuración simple y doble. *MASKAY*, 41-48.
- Zefriz, Y., Sebari, I., Hajji, H., & Aniba, G. (2021). In-depth investigation of applied digital photogrammetry to imagery-based RGB and thermal infrared aerial inspection of large-scale photovoltaic installations. *Remote Sensing Applications: Society and Environment*.
- Zhao, Z., & Moore, J. (2011). Accuracy analysis of polynomial rfm adjustment models for worldview-1 imagery. *International Symposium on Image and Data Fusion*, 1-4.
- Zurita, P. (11 de 2010). *ADOPCION DEL NUEVO MARCO DE REFERENCIA PARA EL ECUADOR*. Obtenido de SIRGAS.ORG:  
[https://www.sirgas.org/fileadmin/docs/Boletines/Bol15/37\\_Zurita\\_et\\_al\\_Reporte\\_Ecuador.pdf](https://www.sirgas.org/fileadmin/docs/Boletines/Bol15/37_Zurita_et_al_Reporte_Ecuador.pdf)