



**Generación de cartografía automatizada 2D a través de la tecnología Deep Learning para
escala 1:5000, en el Sector de Cashapamba**

Argüello Benavides, Edwin Estalin y Garcés Aguirre, Jonhson Fabricio

Departamento de Ciencias de la Tierra y de la Construcción

Carrera de Ingeniería Geográfica y del Medio Ambiente

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

Ing. Kirby Powney, Eduardo Patricio Msc.

09 de septiembre de 2021



Document Information

Analyzed document	ARGUELLO_GARCES_TESIS.docx (D111757225)
Submitted	8/27/2021 4:53:00 PM
Submitted by	
Submitter email	biblioteca@espe.edu.ec
Similarity	1%
Analysis address	ilbbiblioteca.GDC@analysis.orkund.com

EDUARDO PATRICIO KIRBY POWNEY
 Firmado digitalmente por EDUARDO PATRICIO KIRBY POWNEY
 Fecha: 2021.09.08 21:25:00 -05'00'

Sources included in the report

SA	Grupo Difusión Científica / Guamán Sisa Tesis.docx Document Guamán Sisa Tesis.docx (D62430069) Submitted by: jbolanos@difusion.com.mx Receiver: jbolanos.GDC@analysis.orkund.com		2
W	URL: https://www.l3harrisgeospatial.com/docs/backgroundtraindeeplearningmodels.html#EpochsL3Harris Fetched: 8/27/2021 4:54:00 PM		1
SA	Grupo Difusión Científica / TESIS_DAMARIZ MANZANO TOLEDO.pdf Document TESIS_DAMARIZ MANZANO TOLEDO.pdf (D62430068) Submitted by: jbolanos@difusion.com.mx Receiver: jbolanos.GDC@analysis.orkund.com		4
W	URL: http://mascvuex.unex.es/ebooks/sites/mascvuex.unex.es/mascvuex.ebooks/files/files/file/Fotogrametria_9788469713174_0.pdf Fetched: 6/5/2021 6:11:23 PM		1
SA	Capitulo IV_76_Septiembre.docx Document Capitulo IV_76_Septiembre.docx (D41263950)		1
W	URL: https://repository.udistrital.edu.co/bitstream/handle/11349/15113/PuertoCaroLauraNatalia2019.pdf?sequence=25 Fetched: 8/27/2021 4:54:00 PM		1
W	URL: https://www.xatakahome.com/televisores/otro-clavo-ataud-3d-nvidia-dejara-breve-ofrecer-soporte-para-sistema-3d-vision Fetched: 8/27/2021 4:54:00 PM		1
W	URL: https://www.colibri.udelar.edu.uy/jspui/bitstream/20.500.12008/22870/1/DM19.pdf Fetched: 8/27/2021 4:54:00 PM		1



**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 cartografía automatizada 2D a través de la tecnología Deep Learning para escala 1:5000, en el Sector de Cashapamba**” fue realizado por los señores **Capt. Argüello Benavides, Edwin Estalin y Garcés Aguirre, Jonhson Fabricio**; el cual ha sido revisado y analizado en su totalidad por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 09 de septiembre de 2021

EDUARDO PATRICIO KIRBY POWNEY

Firmado digitalmente por EDUARDO PATRICIO KIRBY POWNEY
Fecha: 2021.09.09 07:18:36 -05'00'

.....

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

Nosotros, **Capt. Argüello Benavides, Edwin Estalín y Garcés Aguirre, Jonhson Fabricio**, con cédulas de ciudadanía n° 1718634288 y 1600489999, declaramos que el contenido, ideas y criterios del trabajo de titulación: **Generación de cartografía automatizada 2D a través de la tecnología Deep Learning para escala 1:5000, en el Sector de Cashapamba** 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, 09 de septiembre de 2021

Capt. Argüello Benavides, Edwin Estalín
C.C.: 1718634288

Garcés Aguirre, Jonhson Fabricio
C.C.: 1600489999



DEPARTAMENTO DE CIENCIAS DE LA TIERRA Y DE LA CONSTRUCCIÓN

CARRERA DE INGENIERÍA GEOGRÁFICA Y DEL MEDIO AMBIENTE

AUTORIZACIÓN DE PUBLICACIÓN

Nosotros, **Capt. Argüello Benavides, Edwin Estalin y Garcés Aguirre, Jonhson Fabricio**, con cédulas de ciudadanía n° 1718634288 y 1600489999, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Generación de cartografía automatizada 2D a través de la tecnología Deep Learning para escala 1:5000, en el Sector de Cashapamba** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad.

Sangolquí, 09 de septiembre de 2021

Capt. Argüello Benavides, Edwin Estalin

C.C.: 1718634288

Garcés Aguirre, Jonhson Fabricio

C.C.: 1600489999

Dedicatoria

Este proyecto de titulación es dedicado en primer lugar a mi Dios Todopoderoso, que siempre me está guiando en todas mis decisiones y metas a cumplir, y una ellas fue ser Ingeniero.

A mis padres queridos, Gloria Benavides y Leorgio Argüello, quienes me dieron la vida, me apoyaron en todo momento, y por ellos tengo mi profesión que es la de ser militar.

A mis queridas hermanas, Alexandra y Arletdh, que siempre me estuvieron aconsejando y motivando para culminar con éxito todos los semestres.

A mi querida esposa Tania Enríquez y mi hermoso hijo Samuel Argüello, que fueron el motor principal y mi fortaleza para graduarme de tan prestigiosa Universidad.

A todos mis familiares y amigos que de una u otra manera, aportaron con un granito de arena, para hacer posible una meta más en mi vida.

Edwin Estalin Argüello Benavides

El proyecto se lo dedico principalmente a Dios, quien fue la guía espiritual para cumplir mi sueño de ser un Ingeniero Geógrafo y del Medio Ambiente.

A mis padres queridos, Holguer Garcés y María de los Ángeles Aguirre, por sus enseñanzas, amor y cariño que me brindaron, a pesar de la distancia siempre fueron mi motor principal para luchar día a día y ser un profesional útil para la sociedad.

A mis queridas hermanas Erika y Pamela, por ayudarme con su apoyo incondicional, que de una u otra manera me sirvió de mucho para alcanzar una meta más en mi vida.

A Lisita Calderón, mi queridísima novia, a quien amo y respeto, le doy gracias por estar en las buenas y en las malas, siendo mi confidente y ayudándome a tomar buenas decisiones para ser un ingeniero.

A mis amigos y demás familiares, por brindarme la confianza y aportar para llegar a cumplir uno de muchos objetivos que tengo planificado para mi vida.

Jonhson Fabricio Garcés Aguirre

Agradecimiento

Agradezco al Ejército Ecuatoriano, por darme la oportunidad de estudiar en tan distinguida Universidad de las Fuerzas Armadas “ESPE”, al Instituto Geográfico Militar en el área de Geodesia y Cartográfico, por la prestación de equipos y diferentes software; al mismo tiempo a los ingenieros/as que nos brindaron diferentes capacitaciones.

A mis queridos docentes que tuve la oportunidad de conocerlos en todo el tiempo de estudio, gracias por sus conocimientos impartidos, los mismos que me van a servir de mucho para colaborar en cualquier actividad que como Ingeniero Geógrafo el país lo requiera, siempre haciendo quedar bien al alto a la Universidad.

Al Ing. Eduardo Kirby Mcs. (Tutor del proyecto), muchas gracias por toda la paciencia, estima y consejos que nos supo brindar, para que el proyecto surja de la mejor manera.

Al Ing. Rafael Castro, de la empresa Geospace Solutions; el mismo que nos ayudó con la licencia estudiantil para ENVI Deep Learning

Finalmente a mi compañero de tesis, Fabricio; eterna gratitud por permitirme aprender muchas cosas en el desarrollo del proyecto, por toda esa lealtad y camaradería que tienes querido amigo, muchas felicitaciones y espero que en un futuro no muy lejano, podamos trabajar y compartir experiencias para el beneficio del país.

Edwin Estalin Argüello Benavides

Agradezco a la Universidad de las Fuerzas Armadas “ESPE” y al IGM, por el apoyo brindado para el desarrollo de la investigación.

Al Ing. Eduardo Kirby Msc., por todas sus enseñanzas y consejos, para que la tesis fluya de la mejor manera y a futuro se obtengan buenos resultados para el beneficio del país.

Al Ing. Alexander Robayo Mgs., por la confianza brindada durante toda mi carrera universitaria, por los consejos y experiencias impartidas hacia mí, que me van a servir de mucho para mi carrera profesional.

Al Ing. Rafael Castro por su colaboración en el préstamo de licencias ENVI, para poder desarrollar nuestro proyecto.

A mi compañero de tesis Edwin Argüello, a pesar de los inconvenientes que tuviste, demostraste fortaleza y tenacidad para cumplir una meta más en tu vida.

Jonhson Fabricio Garcés Aguirre

Índice de Contenido

URKUND	2
CERTIFICACIÓN	3
RESPONSABILIDAD DE AUTORÍA	4
AUTORIZACIÓN DE LA PUBLICACIÓN	5
Dedicatoria	6
Agradecimiento	8
Índice de Tablas	14
Índice de Figuras	15
RESUMEN	17
ABSTRACT	18
Capítulo I	19
Generalidades	19
Antecedentes	19
Planteamiento del problema	21
Justificación e importancia.....	22
Área de influencia.....	23
Objetivos.....	25
<i>Objetivo general</i>	25
<i>Objetivos específicos</i>	25
<i>Metas</i>	26
Capítulo II	27
Marco teórico	27
Cartografía.....	27
<i>Clasificación de cartografía</i>	27
<i>Proceso cartográfico</i>	28
Fotogrametría	28
<i>Clasificación</i>	29
<i>Proceso fotogramétrico</i>	30
<i>Restitución</i>	41
<i>Modelos digitales del Terreno</i>	43
<i>Ortofoto</i>	44
<i>Software fotogramétrico</i>	45
Inteligencia artificial	47
<i>Machine Learning</i>	48
<i>Deep Learning</i>	49
Digitalización	62
Vectorización.....	63
<i>Generalización</i>	63

<i>Topología</i>	67
<i>GNSS</i>	68
Control de calidad	71
<i>Calidad</i>	71
<i>Estadísticos</i>	79
Capítulo III	81
Metodología	81
Generalidades	81
Recopilación de la información secundaria.....	83
<i>Fotografía aérea</i>	84
<i>Parámetros de la cámara UltraCam XP</i>	84
<i>APPLANIX</i>	85
Recopilación de información primaria.....	85
<i>Control terrestre</i>	85
Proceso de ajuste fotogramétrico.....	89
<i>Creación del proyecto en ISAT</i>	90
<i>Proceso de orientación interior del ajuste</i>	91
<i>Proceso de orientación relativa</i>	91
<i>Proceso de orientación absoluta</i>	92
<i>Ejecución de la aerotriangulación</i>	93
<i>Evaluación del ajuste fotogramétrico</i>	93
Generación del MDS.....	94
<i>Evaluación del MDS</i>	96
Generación de las ortofotos y ortofotomosaico.....	97
<i>Evaluación del ortofotomosaico</i>	98
Generación de la restitución	99
Proceso de digitalización	101
Proceso de Deep Learning	102
<i>Software utilizado para Deep Learning</i>	102
<i>Requerimientos de hardware para Deep Learning</i>	102
<i>Definición de las clases (objetos a cartografiar)</i>	103
<i>Definición de ráster de entrenamiento, validación y clasificación</i>	103
<i>Extracción de las muestras</i>	104
<i>Entrenamiento de los modelos</i>	105
<i>Métricas de entrenamiento</i>	109
<i>Clasificar un ráster</i>	110

<i>Elección de los mejores modelos entrenados en Deep Learning</i>	111
<i>Exportación de ráster a vector</i>	111
<i>Proceso de edición y generalización</i>	112
Estructuración topológica.....	113
Catalogación de las cartografías	114
Control de calidad de datos	115
<i>Control de Compleción</i>	115
<i>Consistencia lógica</i>	116
<i>Exactitud posicional</i>	117
Evaluación de costos y tiempo de los métodos de generación cartográfica	119
<i>Comparación de costos</i>	119
<i>Comparación de tiempo</i>	119
Capítulo IV	120
Resultados	120
Resultados de la recopilación de información secundaria.....	120
<i>Resultados de la recopilación de fotografía aérea</i>	120
<i>Resultado del APPLANIX</i>	120
<i>Resultado del APPLANIX modificado</i>	121
Resultados de recopilación de información primaria	123
<i>Resultados del control terrestre</i>	123
Resultados del ajuste fotogramétrico	127
Resultado del modelo digital de superficie (MDS)	128
<i>Resultados de la evaluación del modelo digital de superficie</i>	129
Resultados de ortofotos y de Ortofotomosaico	129
<i>Resultados de la evaluación del ortofotomosaico</i>	130
Resultados de la restitución.....	131
<i>Resultado del proceso CAD-SIG</i>	131
Resultados de la digitalización.....	132
Resultados de la generación de cartografía por Deep Learning	133
<i>Resultados de la extracción de muestras en Deep Learning</i>	133
<i>Resultados del entrenamiento de los modelos en Deep Learning</i>	133
<i>Resultados de elección de los mejores modelos en Deep Learning</i>	135
<i>Resultados de edición y generalización</i>	139
Resultados de la catalogación	140
Resultados del control de calidad de datos	141
<i>Resultados de completación</i>	141

<i>Resultados de consistencia lógica</i>	143
<i>Resultados de la exactitud posicional</i>	144
Resultados de la evaluación de costos y tiempo	145
<i>Resultados de comparación de costos</i>	145
<i>Resultados de la comparación de tiempo</i>	146
Capítulo V	147
Conclusiones y Recomendaciones	147
Conclusiones.....	147
Recomendaciones	149
Bibliografía.....	151

Índice de Tablas

Tabla 1. <i>Coordenadas de la zona de estudio</i>	24
Tabla 2. <i>Parámetros recomendados en función de la memoria gráfica (GPU)</i>	58
Tabla 3. <i>Herramientas de generalización</i>	65
Tabla 4. <i>Reglas topológicas en ArcGIS 10.5</i>	67
Tabla 5. <i>Elementos de calidad norma ISO 19157:2013</i>	72
Tabla 6. <i>Tamaño de la muestra en función del área del proyecto</i>	75
Tabla 7. <i>Requerimientos mínimos ENVI Deep Learning</i>	103
Tabla 8. <i>Características puntos de exactitud posicional</i>	117
Tabla 9. <i>Resultados recopilación de fotografía aérea</i>	120
Tabla 10. <i>Archivo APPLANIX modificado</i>	121
Tabla 11. <i>Resultado del elenco de coordenadas Ground Control Point (GCP) y Check Points (CP)</i>	123
Tabla 12. <i>Resultados del elenco de coordenadas de los puntos de control de calidad (PCC)</i>	125
Tabla 13. <i>Resultados estadísticos del modelo digital de superficie (MDS)</i>	129
Tabla 14. <i>Resultados estadísticos ortofotomosaico</i>	130
Tabla 15. <i>Resultados de la extracción de muestras</i>	133
Tabla 16. <i>Resultados del tiempo de procesamiento en los modelos</i>	134
Tabla 17. <i>Parámetros ingresados en los mejores modelos obtenidos</i>	134
Tabla 18. <i>Resultados de parámetros ingresados en los mejores modelos</i>	135
Tabla 19. <i>Resultados de compleción</i>	141
Tabla 20. <i>Resultados de consistencia lógica</i>	143
Tabla 21. <i>Resultados de la exactitud posicional</i>	144
Tabla 22. <i>Resultados comparación de costos</i>	145
Tabla 23. <i>Resultados de la comparación de tiempo</i>	146

Índice de Figuras

Figura 1. Área de estudio	24
Figura 2. Proceso cartográfico	28
Figura 3. Proceso fotogramétrico	31
Figura 4. Orientación externa	33
Figura 5. Orientación relativa.....	34
Figura 6. Condición de coplanariedad.....	35
Figura 7. Condición de colinearidad.....	36
Figura 8. Distribución de Vön Grüber.....	37
Figura 9. Orientación Absoluta	38
Figura 10. Principio de la marca flotante.....	42
Figura 11. Diferencias entre DSM y DTM.....	44
Figura 12. Image Station - Módulos	45
Figura 13. Inteligencia artificial y sus ramas	48
Figura 14. Elementos de una red neuronal.....	51
Figura 15. Funciones de activación mayormente utilizadas	52
Figura 16. Kernel	54
Figura 17. Max pooling	55
Figura 18. Solid Distance (Distancia sólida)	60
Figura 19. Ejemplo de valores de pérdida de validación	61
Figura 20. Métricas TensorBoard.....	62
Figura 21. Tipos de posicionamiento GNSS.....	69
Figura 22. Error estándar en ajuste fotogramétrico	77
Figura 23. Esquema general de la metodología seguida	81
Figura 24. Parámetros de la cámara.....	84
Figura 25. Insumo archivo APPLANIX.....	85
Figura 26. Distribución de los puntos de apoyo fotogramétrico (GCP) y check points (CP).....	86
Figura 27. Posicionamiento del control terrestre.....	88
Figura 28. Diagrama de flujo proceso de ajuste fotogramétrico.....	89
Figura 29. Umbrales para aerotriangulación	91
Figura 30. Extracción de puntos de paso y enlace de manera automática.....	92
Figura 31. Importación de GCP y CP en ISAT.....	93
Figura 32. Generación MDS en INPHO.....	94
Figura 33. Generación de nube de puntos.....	95
Figura 34. Capas para la creación del MDS.....	96
Figura 35. Diagrama de flujo para la generación del ortofotomosaico en INPHO	97
Figura 36. Creación de ortofotos en el módulo de OrthoMaster	98
Figura 37. Diagrama de flujo del proceso de restitución fotogramétrica	100
Figura 38. Diagrama de flujo del proceso CAD-SIG.....	101
Figura 39. Digitalización sobre ortofotomosaico	102
Figura 40. Ráster de entrenamiento, validación y clasificación.....	104
Figura 41. Muestras extraídas para la imagen 1.....	105
Figura 42. Diagrama de flujo para un entrenamiento Deep Learning	106
Figura 43. Parámetros para entrenar un modelo Deep Learning	108
Figura 44. Gráficos de las métricas de entrenamiento	109
Figura 45. Ráster de clasificación y de activación.....	110
Figura 46. Herramienta Convert Classification to Vector ENVI 5.6.....	112
Figura 47. Errores de clasificación y edición de vértices.....	113

Figura 48. <i>GDB y reglas topológicas aplicadas a vías</i>	114
Figura 49. <i>Entidades catalogadas</i>	114
Figura 50. <i>Elementos aplicables de la norma ISO 19157</i>	115
Figura 51. <i>Distribución de cuadrícula para el control de compleción</i>	116
Figura 52. <i>Consistencia de dominio</i>	117
Figura 53. <i>Extracción de vértices cercanos</i>	118
Figura 54. <i>Archivo APPLANIX</i>	121
Figura 55. <i>Resultados de las monografías (GCP1)</i>	124
Figura 56. <i>Resultados del proceso de aerotriangulación ISAT</i>	127
Figura 57. <i>Resultados del modelo digital de superficie (MDS)</i>	128
Figura 58. <i>Ortofotomosaico</i>	130
Figura 59. <i>Resultado de restitución - Archivo .DGN</i>	131
Figura 60. <i>Resultados de la cartografía por restitución catalogada</i>	132
Figura 61. <i>Resultados de la cartografía por digitalización catalogada</i>	132
Figura 62. <i>Resultados de ráster de clasificación de los mejores modelos</i>	136
Figura 63. <i>Resultados de las métricas de los mejores modelos escogidos</i>	137
Figura 64. <i>Resultados del proceso de edición y generalización</i>	139
Figura 65. <i>Resultado de mapa generado por la técnica Deep Learning</i>	141

RESUMEN

La inteligencia artificial (IA), en la actualidad es una herramienta auxiliar en la toma de decisiones, en cuanto tienen la capacidad de resolver problemas de forma autosuficiente. El inconveniente de elaborar cartografía, a través del método de restitución fotogramétrica y digitalización, es que son procesos que conllevan tiempo, recursos, personal especializado; además de hardware y software sumamente costosos. Por tal razón surge la necesidad de generar, comparar y evaluar cartografía, por métodos tradicionales e inteligencia artificial a través de Deep Learning, para escala 1:5000, en el sector de Cashapamba, con la finalidad de obtener cartografía 2D. A partir de información primaria (puntos de apoyo fotogramétrico), secundaria (fotografía aérea, APPLANIX, certificado de calibración), se generaron insumos como ajuste fotogramétrico, modelo digital de superficie y ortofotomosaico. Los objetos de extracción cartográfica fueron: vías, ríos, edificios, manzanas y parterre. Se elaboró cartografía por el método de restitución a partir del bloque generado; desde el ortofotomosaico, se digitalizó y ensayó modelos de Deep Learning. En los entrenamientos se tomaron muestras de forma poligonal, escogiendo los tres mejores modelos, se clasificó el área de estudio, para finalmente trasladar la información a formato vector; la misma que pasó un proceso de edición y generalización. A las bases resultantes se les realizó una estructuración topológica y catalogación; para luego aplicarles la norma ISO 19157 en temas de compleción, consistencia lógica, y exactitud posicional. A los productos generados se les evaluó a través de los estándares NSSDA. Finalmente, se ejecutó una comparación de costo y tiempo entre las cartografías. Los resultados fueron: un ajuste fotogramétrico, modelo digital de superficie, y ortofoto para 4000 ha; cartografía catalogada de restitución, digitalización y Deep Learning en 200 ha; evaluación de calidad de datos geográficos, y tablas de exactitud posicional, comparación de costos y tiempo. En conclusión, es posible la generación de cartografía por Deep Learning para escala 1:5000, considerando que no se pudo generar objetos de tipo lineal, ni puntual.

Palabras clave:

- **INTELIGENCIA ARTIFICIAL**
- **DEEP LEARNING**
- **CARTOGRAFÍA**
- **EXACTITUD POSICIONAL**

ABSTRACT

Artificial intelligence (AI) is currently an auxiliary tool in decision-making, insofar as they have the ability to solve problems in a self-sufficient way. The drawback of developing cartography, through the photogrammetric restitution and digitization method, is that they are processes that involve time, resources, and specialized personnel; as well as extremely expensive hardware and software. For this reason, the need arises to generate, compare and evaluate cartography, by traditional methods and artificial intelligence through Deep Learning, for a scale of 1: 5000, in the Cashapamba sector, in order to obtain 2D cartography. From primary information (photogrammetric support points), secondary (aerial photography, APPLANIX, calibration certificate), inputs such as photogrammetric adjustment, digital surface model and orthophotomosaic were generated. The cartographic extraction objects included: roads, rivers, buildings, blocks and parterre. Cartography was elaborated by the restitution method from the generated block; from the orthophotomass, Deep Learning models were digitized and tested. In the training, polygonal samples were taken, choosing the three best models, the study area was classified, to finally transfer the information to vector format; the same one that went through an editing and generalization process. The resulting bases underwent a topological structuring and cataloging; and then the ISO 19157 standard was applied on issues of completeness, logical consistency, and positional accuracy. The products generated were evaluated through the NSSDA standards. Finally, a cost and time comparison was made between the cartographies. The results were: a photogrammetric adjustment, digital surface model, and orthophoto for 4000 hectares; cataloged mapping of restitution, digitization and Deep Learning in 200 hectares; geographic data quality assessment, and positional accuracy tables, cost and time comparison. In conclusion, it is possible to generate cartography using the Deep Learning method for a 1: 5000 scale, considering that it was not possible to generate linear or punctual objects.

Keywords:

- **ARTIFICIAL INTELLIGENCE**
- **DEEP LEARNING**
- **CARTOGRAPHY**
- **POSITIONAL ACCURACY**

Capítulo I

Generalidades

En el siguiente capítulo se detalla una introducción al desarrollo del proyecto, aquí se resumen: proyectos relacionados, planteamiento del problema, su justificación y la importancia que tendrá el mismo, delimitación del área de estudio, objetivos tanto general como específicos y metas.

Antecedentes

“El Instituto Geográfico Militar (IGM), entidad de derecho público y personería jurídica, autonomía administrativa y patrimonio propio, orgánica y disciplinariamente subordinado a la Comandancia General del Ejército, con sede en la ciudad de Quito, tendrá a su cargo y responsabilidad la planificación, organización, dirección, coordinación, ejecución, aprobación y control de las actividades encaminadas a la elaboración de la Cartografía Nacional y del Archivo de Datos Geográficos y Cartográficos del País”(Ley De Cartografía Nacional, 1978, Art. 1).

A partir de enero de 2018, el IGM tiene a su disposición la ejecución del proyecto para obtener la cartografía básica de carácter oficial, actualizada del país en diferentes escalas, y que cuenta con una asignación presupuestaria de USD 20'398.690,63. Previo a su ejecución se contaba con una cobertura de cartografía básica planimétrica a escalas 1:5000, 1:10000, 1:25000, 1:50000, 1:100000 y 1:250000 del 82% del territorio con actualización en el año 2011; en cuanto a cartografía altimétrica a escala 1:5000, se cuenta con solo el 1% del territorio nacional (IGM, 2019).

La inteligencia artificial (IA), con el venir de los años, se ha convertido en una de las herramientas auxiliares en la toma de decisiones, en cuanto tienen la capacidad de

resolver problemas de forma autosuficiente, con base en los datos de entrada que se les ha proporcionado (Almeida et al., 2018). Existen campos entre los cuales se desarrolla la IA como son: los videojuegos, conducción de vehículos autónomos, traducción de lenguaje, reconocimiento de audios, clasificación de imágenes, entre otras aplicaciones. Estos sistemas simulan la actuación del ser humano ante una tarea de carácter cognitivo (Lepage Chumpitaz, 2016).

Como parte de la IA se encuentra el Machine Learning (ML) o aprendizaje automático, el mismo que permite la utilización de mecanismos con capacidad computacional, que generan conocimiento y correlacionan los datos proporcionados; todo esto con el fin de establecer patrones que ayuden a pronosticar conductas y tomar decisiones (Ramiro & Alvarado, 2020). Otra rama de la IA es el Deep Learning o aprendizaje profundo, caracterizado por ganar conocimiento de forma automática, mediante algunos niveles. Su virtud es que no necesita determinar las características de los patrones, sino más bien, esto se desarrolla automáticamente logrando tener características de alto rango, mediante algunos niveles jerarquizados de extracción, en un sistema que aprende automáticamente (Gómez, 2016).

A nivel global se han desarrollado diversos trabajos en temas de Deep Learning, en el campo de la geografía, como por ejemplo el realizado por (De la Fuente, 2019), en el que se incursiona en el mundo de la fotografía aérea orto rectificadas, con la finalidad de inspeccionar y mantener la cartografía de vías de transporte a través de Deep Learning, consiguiendo implementar una librería de algoritmos con la facultad de entrenar y evaluar sobre entornos de multi-GPU, aproximando de manera automática el tamaño de lote.

Por otro lado Solovey (2017), lleva a cabo un procedimiento para la extracción y clasificación de tipos de terreno e infraestructuras, mediante la utilización de una

fotografía aérea de alta resolución, como una posible alternativa para la generación de mapas de combustible de forma automática. En temas de clasificación se pone en práctica una red neuronal convolucional pre entrenada por AlexNet y adaptada para trabajar con las clases definidas. La precisión obtenida para las imágenes de entrenamiento es del 77% y el 80%. Las matrices de confusión demuestran que en la clase de vegetación es posible tener un 96% de precisión.

De manera similar Spolti (2018), realiza la aplicación de arquitecturas Deep Learning, para la clasificación de vías, teniendo como insumo una imagen aérea. Las arquitecturas utilizadas fueron U-Net que se comparó con AutoEncoder, de ellas obtiene el 92.8% y 88.9% de precisión respectivamente; estos resultados, demuestran que se puede aplicar estas arquitecturas para resolver este tipo de problemas.

Mayorga & Andaluz (2018), en Ecuador, llevaron a cabo la evaluación del nivel de fatiga en el conductor de un vehículo, de tal forma que se implemente la conducción de manera automática, esta detección se encuentra fundamentada en el reconocimiento facial a través de Deep Learning. Como resultado de esto, se tiene un indicador de 4 clases, en concordancia con la posición y velocidad del vehículo, se recalcula la ruta y la distancia más corta.

Planteamiento del problema

El inconveniente de elaborar cartografía a través del método de restitución fotogramétrica, es que evidencia ser un proceso complicado, que conlleva tiempo, recursos, personal especializado; además de hardware y software sumamente costosos; esto trae como resultado, que no se pueda tener cartografía actualizada de forma constante (Jarandilla, 2014). Adicionalmente, existe una tendencia a que los

sistemas 3D (equipos, soporte, accesorios) desaparezcan, herramientas que son indispensables para la restitución fotogramétrica (Xakata, 2020).

La digitalización es un método bastante utilizado en la elaboración de cartografía, en la que se tiene como insumo una ortofoto, ortofotomosaico o imagen satelital, al ser una técnica en 2D posibilita la extracción de elementos planimétricos. El problema está al igual que en la restitución, en costos elevados, tiempo de generación y personal capacitado (Moreno & Ramírez, 2018) (Santos, 2007) (IGM, 2013).

Por lo tanto, surge la necesidad de generar cartografía de manera automática en menor tiempo y de calidad. La intención de este trabajo es conseguir la elaboración de cartografía haciendo uso de la tecnología Deep Learning para escala 1:5000, además evaluar la generación de cartografía por métodos tradicionales (digitalización y restitución), a partir de insumos como el bloque fotogramétrico y ortofotomosaico, elaborados por el IGM; enfatizando el análisis en el tiempo de realización, recursos, calidad y precisión de los productos obtenidos. Finalmente, verificar si es factible la incursión de esta alternativa en la elaboración de cartografía, que se encuentre a la par con los desarrollos tecnológicos del mundo actual.

Justificación e importancia

En los últimos años existe una tendencia a resolver problemas a través de inteligencia artificial y más específicamente con la tecnología de Deep Learning, como por ejemplo: el reconocimiento de voz, tratamiento de texto, ordenación de imágenes e incluso en la medicina (Mora, 2016).

A lo largo del tiempo, el IGM ha venido actualizando y automatizando sus procesos, en cuanto a la obtención de cartografía base en el Ecuador, a través de la captura de información por métodos de restitución fotogramétrica. El problema radica en

que es un proceso que conlleva mucho tiempo, costos elevados, personal capacitado y soporte tecnológico (Jarandilla, 2014). Esto conlleva a la necesidad de buscar alternativas para automatizar la extracción de ciertos elementos de la superficie terrestre, y que los datos obtenidos sean de calidad, procurando tener actualización permanente.

Es de gran interés saber de alternativas para generar cartografía automática, de tal forma que se pueda levantar en un período corto y tener un ahorro en tiempo y recursos. En ese sentido, el proyecto es importante debido a que tendrá un beneficio nacional, en tanto que será una alternativa para la generación de cartografía, que puede ser de utilidad para los entes de planificación en el país como instituciones públicas y gobiernos autónomos. Por otro lado, esta alternativa de extracción de datos geográficos podría ser de ayuda en los procesos del IGM, debido a que su intención es evaluar si es factible la generación de cartografía automatizada en escala 1:5000, logrando así minimizar tiempo y recursos.

Con respecto a la academia, será útil debido a que se encuentra una primera aproximación a esta nueva tecnología, para elaborar cartografía de forma alternativa, pudiendo dejar un abanico de nuevas investigaciones y aplicaciones que se relacionen con la inteligencia artificial y más específicamente con la tecnología de Deep Learning.

Área de influencia

El área de estudio propuesta para esta investigación es en el sector de Cashapamba, parroquia urbana de Sangolquí, perteneciente al cantón Rumiñahui en la provincia de Pichincha (GADMUR, 2019). Se escoge esta zona de estudio debido a la gran cantidad de elementos existentes que pueden ser cartografiados, tanto de carácter urbanos como rurales (definidos por la zona edificada). En la tabla 1, se muestran las

coordenadas de los límites que componen el área de estudio y en la figura 1, se ilustra dicho sector.

Tabla 1.


Coordenadas de la zona de estudio

ID	Este	Norte
P1	785143.000	9963531.000
P2	787143.000	9963531.000
P3	785143.000	9962531.000
P4	787143.000	9962531.000

Nota: Elaboración propia. Sistema de referencia WGS84 Proyección UTM 17 S.

Figura 1.

Área de estudio



Objetivos

Objetivo general

Generar, comparar y evaluar cartografía, por métodos tradicionales e inteligencia artificial a través de Deep Learning, para escala 1:5000, en el sector de Cashapamba, con la finalidad de obtener cartografía 2D alternativa.

Objetivos específicos

- Recopilar y estandarizar la información secundaria (ajuste fotogramétrico y ortofotomosaico) de la zona de estudio con la finalidad de tener los insumos para la generación de cartografía por los diferentes métodos.
- Generar y depurar la cartografía 2D automatizada, a través de la tecnología Deep Learning y herramientas SIG, para la obtención de cartografía alternativa en la zona de estudio y su correspondiente evaluación.
- Restituir en el área de intervención a partir del ajuste fotogramétrico con la finalidad de generar cartografía 3D, y confrontar los productos con los otros métodos de obtención.
- Elaborar cartografía 2D, a través del método de digitalización o vectorización, en el área de intervención, a partir de un ortofotomosaico, con el objeto de evaluar el proceso de captura.
- Medir puntos de control horizontal y vertical, mediante técnicas GNSS de acuerdo al Protocolo (IGM, 2018), para evaluar la exactitud posicional de las cartografías obtenidas.
- Evaluar la calidad de los productos generados, a través de la Norma ISO 19157, con el objeto de verificar la precisión de las cartografías obtenidas.

- Comparar el costo, tiempo y la calidad de la cartografía obtenida por los diferentes métodos de extracción, estableciendo sus ventajas y desventajas; así como la precisión para cartografía escala 1:5000.

Metas

- Un ajuste fotogramétrico de la zona de estudio en formato digital.
- Un ortofotomosaico del área de intervención en formato digital.
- 200 ha de cartografía escala 1:5000, a través de la tecnología Deep Learning evaluada a través de la norma ISO 19157 que se han de incluir en una geodatabase.
- 40 ha de cartografía elaborada a través de digitalización/vectorización escala 1:5000, evaluada a través de la norma ISO 19157, que ha de ser incorporada en una geodatabase.
- 40 ha de cartografía 3D elaborada por restitución fotogramétrica y evaluada a través de la norma ISO 19157, almacenada en una geodatabase.
- 20 monografías de los puntos de control obtenidos para la evaluación de la exactitud posicional, en conformidad con el protocolo propuesto por IGM en 2018.
- Un informe técnico de la calidad de datos obtenidos a través de la norma ISO 19157, para los diferentes métodos de elaboración de cartografía.
- Una matriz comparativa de costo, tiempo y calidad de datos, de los diferentes métodos de generación de cartografía.

Capítulo II

Marco teórico

En este capítulo se describe el enfoque teórico básico utilizado en la presente investigación, en donde se mencionan aspectos como cartografía, fotogrametría, inteligencia artificial, digitalización, y control de calidad.

Cartografía

Considerada como la disciplina, ciencia o arte que tiene a su cargo el estudio de métodos, sistemas, operaciones y técnicas, que a través de su utilización se puede representar en un plano, de toda o una parte de la superficie de la Tierra (grandes extensiones de territorio), además de los fenómenos que actúan sobre ella, teniendo como resultado un mapa o una carta. Para que esta representación se lleve a cabo será necesario determinar una proyección de la antes mencionada superficie terrestre (IGAC, 2016; Millán, 2006).

Clasificación de cartografía

Cartografía topográfica. Se caracteriza por la representación de los diferentes accidentes geográficos que se encuentran en el territorio, estos pueden ser de tipo natural como: ríos, valles, montañas; o artificiales como: postes, aceras, vías, ciudades entre otras. Para llevar a cabo esta representación se han de emplear puntos (ejm. valores de altura), líneas (como lo son las curvas de nivel) o polígonos (como por ejemplo para demarcar el cauce de un río) (S. López & Martín, 2016).

Cartografía temática. Sobre una base de cartografía topográfica, se pueden incluir una o algunas variables que caracterizan el territorio, entre las que se encuentran las físicas (pendientes, etc.), ambientales (distribución de especies, uso y clasificación del suelo, etc.), sociales (densidad de población, población en situación de migración,


etc.), económicas (desempleo, población económicamente activa, etc.) entre muchas otras variables que pueden ser cartografiadas y consideradas como temáticas (S. López & Martín, 2016).

Proceso cartográfico

La unión de procesos que convierten la información geográfica en un mapa es denominado proceso cartográfico. Está determinado por tres etapas, una primera denominada concepción del mapa (objetivo, usuario, costos, tiempo, etc.), luego vendrá la producción (recopilación de la información, diseño, producción y comercialización), finalmente el cliente dará uso a este mapa (Redgeomática, 2018). En la figura 2, se visualiza un esquema del proceso cartográfico.

Figura 2.

Proceso cartográfico



Fotogrametría

La fotogrametría se encuentra establecida como una rama de la teledetección, que se define como el arte, ciencia y tecnología a través de la cual, se pueden obtener medidas confiables de objetos físicos y el ambiente que los rodea, por medio del

registro, medida e interpretación de fotografías, prototipos de energía radiante electromagnética y otros fenómenos (ASPRS, 2009).

También, es considerada como la ciencia que nos ayuda en la medición de objetos reales, teniendo como insumo sus fotografías, estas pueden ser de tipo terrestre o aéreas, cuya finalidad es la de presentar un mapa topográfico (Orellana, 2006). Otra definición es la unión de métodos y procedimientos, a través del cual, se puede obtener las medidas del objeto desde una fotografía (Santamaría & Sanz, 2011).

Clasificación

En función del instrumento utilizado

Analógica. Nace en la década de 1930, teniendo como base aparatos de restitución y se ha considerado como la responsable de la cartografía mundial. Para ello, dos fotografías consecutivas debían ser colocadas en un restituidor mecánico. El operador desarrolla manualmente la orientación interior y exterior, para formar el modelo estereoscópico, que deberá estar escalado y nivelado. La información se levanta manualmente tanto en planimetría, como en altimetría; utilizando el principio de la marca flotante en la superficie del modelo. Los datos son escritos sobre la cartulina ubicada en la mesa de trazo (Jauregui, 2012).

Analítica. Surge en el año 1957, a consecuencia de la relación entre los aparatos analógicos y los inicios de la computación. Su característica es que gran parte del trabajo que se realiza en los restituidores; es más económica, debido a la aplicación de modelos matemáticos a objetos físicos. Se encuentra basado en la ejecución de los cálculos fotogramétricos mediante el uso de la informática, esto permite conseguir de forma rápida las relaciones entre los puntos del objeto fotografiado y sus imágenes (Jauregui, 2012).

Digital. Actualmente se encuentra en auge, surge como resultado del gran avance computacional, logrando que todos los procesos fotogramétricos se los realicen por medio de un computador. Con ello aumentan las posibilidades de utilización de imágenes, en temas como generación de modelos digitales de elevación, orto imágenes y estéreo imágenes, crear y visualizar modelos tridimensionales, entre otras. Para restituir digitalmente, las imágenes son ingresadas en el computador y a través de la visualización en pantalla, el operador inserta los puntos requeridos para que el proceso de orientación se genere de forma matemática. Los resultados pueden ser vectoriales o ráster (Jauregui, 2012).

En función de la distancia del objetivo

Fotogrametría terrestre. Se caracteriza por la utilización de fotografías que han sido tomadas en una base terrestre, en tal razón la posición y los elementos de la orientación externa de la cámara, ya son conocidos. En la actualidad tiene su aplicación en temas de arquitectura, arqueología y levantamientos de tipo topográficos, en terrenos muy escarpados, su empleo se da cuando la fotogrametría aérea es muy costosa o es casi imposible de realizarla (Luna, 2009).

Fotogrametría vertical. Está representada por el uso de fotografía tomada desde una cámara aerotransportada, implícitamente tiene el eje óptico de manera vertical, además que su localización no se encuentra determinada. Su aplicación más aceptada es la de generar cartografía, en razón de su accesibilidad económica, adaptación a cualquier tipo de terreno y variación de la escala (Luna, 2009).


Proceso fotogramétrico

Se conoce como proceso fotogramétrico, al conjunto de pasos de carácter consecutivo, que como resultado se tiene la elaboración de cartografía. Inicia con la

toma de la fotografía, finalizando con la consecución de coordenadas en tres dimensiones, que luego darán origen a mapas cartográficos, modelos digitales de elevación, ortofotos entre otros productos. Conlleva trabajo en campo y gabinete, acumulando los errores y precisiones de todos los procesos, en consecuencia la calidad del resultado dependerá de la calidad de cada una de las fases (Quirós, 2014). En la figura 3, se esquematiza el proceso fotogramétrico.

Figura 3.

Proceso fotogramétrico



Ajuste fotogramétrico


Orientación interna. También llamada orientación interior, aquí se establece la geometría del sensor como se encontraba al momento de realizar la captura de los

datos (Orellana, 2006). Es el proceso mediante el cual, se transforma el sistema de coordenadas pixel (fila, columna) al sistema de coordenadas de la cámara (mm), y se encuentran en referencia a un sistema cartesiano 2D, en donde el origen está en el centro de proyección de la cámara. Aquí se corregirán errores de (Quirós, 2014):

- Punto principal
- Película fotogramétrica
- Distorsiones del objetivo
- Refracción atmosférica
- Esfericidad terrestre


Orientación interna con cámaras digitales. En imágenes que han sido capturadas con una cámara digital, la orientación interna está dada por la determinación de la posición del punto principal de la foto, en relación con el centro de la imagen digital (fila, columna). Las imágenes digitales no poseen marcas fiduciales, por lo que el proceso es automático en su totalidad. Solamente se deberá establecer los parámetros de calibración de la cámara con la que se realizó la toma (Quirós, 2014).

Orientación externa. Para este proceso es necesario conocer la posición exacta de dos puntos (A y B), en temas de inclinación y desvío que la cámara tuvo en el momento que se realizó la toma. Hasta la actualidad no existe un equipo que nos pueda dar estos datos, por lo que se recurre al mismo restituidor y de puntos de apoyo en el terreno, mediante técnicas topográficas de campo (Santamaría & Sanz, 2011). Esta orientación determina la orientación angular y la posición de la imagen al momento de la captura. Se divide en relativa y absoluta (Orellana, 2006). En la figura 4 se presenta el proceso de orientación relativa.

Figura 4.*Orientación externa*

Nota: Recuperado de (Santamaría & Sanz, 2011).

Orientación relativa. Es la parte del proceso fotogramétrico, en donde se relacionan geoméricamente las imágenes estereoscópicas, formándose un modelo estereoscópico. Consiste en determinar puntos homologos en cada fotografía, para posteriormente reconstruir los haces de luz que dieron origen y crear así el modelo estereoscópico. Para esto es importante la condición de coplanariedad (Quirós, 2014). En la figura 5 se evidencia la orientación relativa.


Figura 5.*Orientación relativa*

Nota: Recuperado de (Quirós, 2014).

- Coplanariedad: condición en la que los dos centros de proyección tanto el izquierdo como el derecho (O_1 y O_2), un punto cualquiera en terreno (A) y sus homólogos (a_1 y a_2) se encuentran en un mismo plano (Sánchez, 2007). En la figura 6 se ilustra un esquema de la condición de coplanariedad.


Figura 6.

Condición de coplanariedad



Nota: Recuperado de (Sánchez, 2007).

- Colinearidad: está definida por la condición de que el centro de proyección (O), el punto imagen en la fotografía (a) y el punto en el terreno (A), se encuentran en la misma recta (Sánchez, 2007). En la figura 7 se visualiza la condición de colinearidad.


Figura 7.*Condición de colinearidad*

Nota: Recuperado de (Sánchez, 2007).

La orientación relativa estará realizada, una vez producida la intersección de todos los rayos homólogos. Será necesario de al menos 6 puntos de intersección, siguiendo la distribución de Vön Grüber, para tener la formación del modelo. Estos puntos pueden ser identificados de forma manual, aunque en los restituidores de tipo digital se ofrece la realización de este proceso de manera automática, por medio de técnicas de correlación. Esta correlación no siempre se realiza de la mejor manera (puntos en sombras, automóviles en movimiento), por lo que se requiere de una revisión exhaustiva de parte del operador (Quirós, 2014). En la figura 8, se esquematiza la distribución para los puntos de Vön Grüber.


Figura 8.

Distribución de Vön Grüber



Nota: Recuperado de (Quirós, 2014).

Orientación absoluta. Una vez realizada la orientación relativa, surge la necesidad de posicionar el modelo en un sistema de coordenadas absoluto. Este proceso trata la nivelación, escalado y traslado del modelo a su verdadera posición en el espacio. Para llevar a cabo la orientación, es necesario conocer al menos 4 puntos en el sistema de coordenadas del modelo como en el terreno, que resolverán un sistema de 3 ecuaciones y 7 incógnitas mediante el método de mínimos cuadrados (Quirós, 2014). En la figura 9 se presenta la orientación absoluta.

Figura 9.*Orientación Absoluta*

Nota: Recuperado de (Quirós, 2014).

Orientación directa. Considerada como la técnica que ayuda a los topógrafos cuando encuentran dificultades en el terreno, y por lo tanto, el trabajo de campo no se realiza de la mejor manera; en consecuencia, existen retrasos en el levantamiento fotogramétrico. La técnica consiste en un sistema conformado por dos receptores GPS (terrestre y aerotransportado) que proporcionan información sobre los centros de proyección (X_0 , Y_0 , Z_0), y una unidad de medida inercial (IMU) que mide los giros (ω , ϕ , κ), obtenidos al momento de la toma de la imagen. Para que todas las imágenes se encuentren en un mismo sistema de referencia es necesario realizar la calibración del sistema GPS-INS (García Flores & Ortiz de Elguea, 2012).

Puntos de apoyo fotogramétrico. Para poder efectuar la orientación absoluta, es necesario saber las coordenadas referidas a la superficie terrestre, de una serie de puntos, con esto se conseguirá ajustar la escala, además nivelar el modelo. Estos puntos deberán ser identificables en la fotografía. La definición de las coordenadas tanto en planimetría (control horizontal) como en vertical (control vertical) recibe el

nombre de control terrestre (García Flores & Ortiz de Elguea, 2012; Ríos & Puerto, 2019).

Puntos de control terrestre. También llamados Ground Control Points, están definidos como grandes objetivos que han de ser visibles en al menos dos fotografías, y distribuidos estratégicamente a lo largo del bloque fotogramétrico. Estos puntos de control terrestre con sus coordenadas, se utilizan para facilitar al software fotogramétrico, llevar el levantamiento a su verdadera posición en la tierra. Estos ayudan a mejorar en gran medida la precisión global del bloque fotogramétrico (DronDeploy, 2019). Según (Claros Z. et al., 2016) sus características deben ser:

- Perfectamente identificables en las fotos donde aparece.
- Los puntos se marcarán dentro de la zona establecida en el plan de vuelo, en razón de que se encuentren distribuidos homogéneamente.
- En lo posible ha de ser un detalle artificial y estable.
- Ubicarlos en partes con pendiente plana, con la finalidad de que no presenten problemas en vista estereoscópica.
- Cada GCP deberá ser visible en al menos 5 fotografías, con el objetivo de reducir imprecisiones.

Puntos de chequeo. También llamados Check Points, son puntos con coordenadas 3D conocidas, que nos ayudan a verificar de manera independiente la calidad y precisión general del bloque fotogramétrico, realizando una comparación entre las coordenadas calculadas por el software fotogramétrico, con las obtenidas a través de métodos topográficos. Como resultado se obtiene un RMSE (error cuadrático medio), que detalla la correspondencia entre los valores calculados con los originales, valores bajos indican un mejor ajuste (Claros Z. et al., 2016).

Puntos de enlace o Tie Points. Son aquellos puntos que son comunes entre las imágenes, por lo que no es necesario que se les atribuya coordenadas. Los puntos de enlace han de ser distribuidos en todo el bloque fotogramétrico. Más bien, una vez concluido el proceso de triangulación, se pueden calcular las coordenadas de los mismos, convirtiéndolos en puntos de control (Caimel Benítez, 2002).

Aerotriangulación. Es una parte del ajuste fotogramétrico, en la orientación exterior, cuyo objetivo es reducir el número de puntos de apoyo que se toman en campo. Permite establecer los parámetros de orientación (ω , ϕ , κ), además de las coordenadas del punto principal (X_0 , Y_0 , Z_0), así como también, coordenadas de algunos puntos espaciales. Con este proceso se logra minimizar gastos topográficos que se relacionan con la rectificación de imágenes (Lerma, 2002; Quirós, 2014). Entre los métodos de aerotriangulación se encuentran:

Aerotriangulación por pasadas. En la actualidad se encuentra en desuso, debido a que se realizaba en equipos analógicos, y se encontraba condicionado debido a la capacidad de cálculo que se tenía hace algunas décadas (Lerma, 2002).

Aerotriangulación por modelos independientes. En este método se ajusta de manera relativa a todos los modelos del bloque fotogramétrico, al final se tendrá una serie de modelos independientes con su propia escala y sistema de coordenadas. Posteriormente haciendo uso de los puntos de enlace, control y de paso, a través de transformaciones semejantes de Helmert, se logra una orientación absoluta en todos los modelos (Instituto Geográfico Nacional, 2010).


Aerotriangulación por el método de haces de rayos. La unidad de trabajo es el fotograma. Se obtiene de la condición geométrica de que el punto objeto P, el centro de proyección O y el punto en la imagen P' se encuentran en la misma recta, por lo que

da origen a las ecuaciones de colinearidad. Al ser un problema de intersección inversa espacial, se observan las fotocoordenadas de los puntos de paso y de los punto de control que aparecen en la imagen con la finalidad de obtener la coordenadas del centro de proyección y de su orientación en el espacio (Instituto Geográfico Nacional, 2010; Lerma, 2002).

Restitución

La etapa final del proceso fotogramétrico es la restitución. Es definida como el proceso en el cual se extrae la información (detalles cartográficos) planimétrica y altimétrica, a partir de modelos estereoscópicos, aplicando el principio de la marca flotante. Los elementos extraídos por este método son registrados en un software CAD, razón por la cual, siempre se necesitará de un trabajo de edición. La información que se extrae y su detalle estará en función de la escala a la que se va a presentar la cartografía final (IGAC, 2016; Jarandilla, 2014; Sánchez, 2007).

Principio de la marca flotante. Al observar un modelo estereoscópico se colocan marcas iguales en los puntos homólogos de las fotografías, estas se verán como una sola en forma de marca flotante. Al mover estas marcas, una con respecto a la otra y en sentido paralelo a la línea de vuelo, ésta subirá o bajará respecto al terreno. Basado en este principio y establecido en las ecuaciones de paralaje, se puede calcular las diferencias altimétricas entre puntos (Reuter, 2002). En la figura 10 se evidencia el esquema del principio de la marca flotante.

Figura 10.*Principio de la marca flotante**Nota:* Recuperado de (Sánchez, 2007).

Archivo semilla. Permite establecer diseños al espacio de trabajo, incluyendo ajustes personalizados, con el fin de que las entidades extraídas posean atributos preestablecidos como el grosor, color, tipo de líneas, etc. Generalmente se trabaja con archivos DGN que permite el dibujo 2D y 3D en el software Microstation. No necesariamente deberá contener elementos, sino, más bien, un modelo creado de tal forma que las configuraciones iniciales se las haga una sola vez (Guamán, 2020).

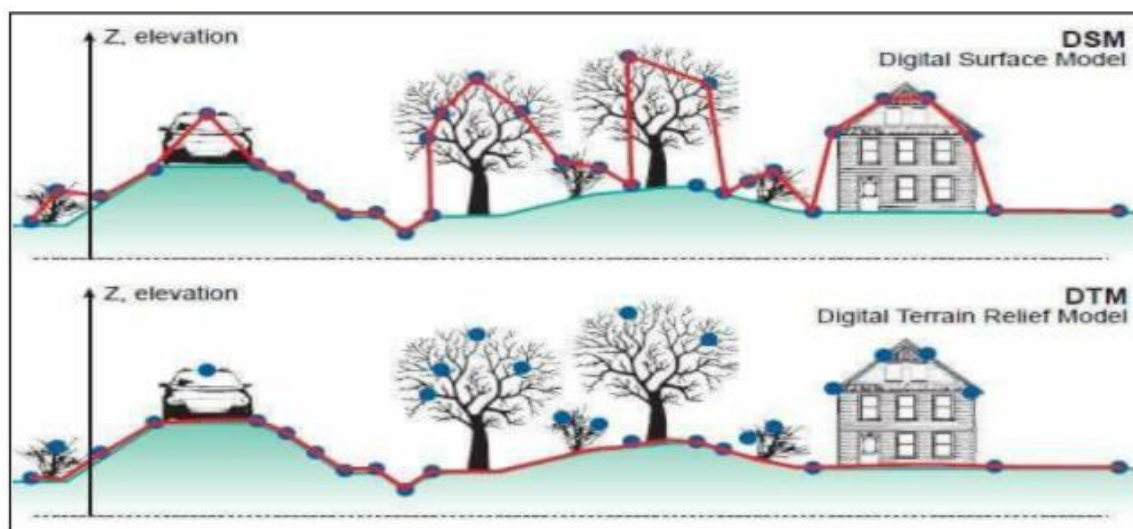
Restitución 3D. En este proceso se trata de dibujar todos los objetos espaciales, con la consideración de que estos deberán tener una altura o cota específica, extrayendo de esta forma coordenadas tridimensionales (x, y, z), en un determinado sistema de referencia. Con esta forma de restituir se puede establecer el relieve del terreno a través de la digitalización de curvas de nivel y puntos con cotas (Barragán, 2015).

Modelos digitales del Terreno

Modelo Digital del Terreno (MDT). Es considerado como el conjunto de capas (casi siempre de tipo ráster), que muestran distintas características de la superficie de la tierra, proceden de una capa de elevaciones. Entre ellas pueden incluir datos de pendiente, orientación, curvatura, entre otras. Algunas veces se dice que el MDT puede representar cualquier tipo de variable cuantitativa y con continuidad espacial (ejm. pH, Na, etc.) (Sarría, 2015).

Modelo digital de elevaciones (MDE). Es una estructura numérica de datos, en la que se representa la distribución espacial de altitud en la superficie terrestre. De esta forma existen algunas soluciones para representar altitud, las mismas que han sido diseñadas con la finalidad de facilitar el manejo y tener una descripción realista del terreno. Estas estructuras pueden ser de tipo vectorial (contornos, redes de triángulos irregulares TIN) y modelos ráster (matrices regulares, matrices de resolución variable) (Felicísimo, 1994).

Modelo digital de superficie (MDS). Se define como una estructura numérica, donde los datos representan además de la altura del terreno los elementos que a ella se enlazan como son edificaciones, árboles, etc. Un MDS es rentable cuando representa el relieve en 3D y tiene aplicación en telecomunicaciones, aviación y planificación urbana (Ibáñez, 2008). Es útil para la clasificación de características en orto imágenes, en caso de tener un buen MDS se lo puede utilizar para la generación de ortofotos verdaderas (ESRI, 2021). En la figura 11, se indica las diferencias entre DSM y DTM.

Figura 11.*Diferencias entre DSM y DTM*

Nota: Recuperado de GIS & Remote Sensing Service (2018) como se citó en (Chuquitarco, 2018)

Ortofoto

Es la conformación de aerofotografía, en la que las distorsiones debido a la topografía del terreno como la elevación e inclinación, han sido corregidas por algún método de orto rectificación, teniendo como resultado, la impresión de que los objetos son vistos desde arriba. A consecuencia de que la fotografía se encuentra en proyección ortogonal, los objetos están en posición planimétrica (X,Y) y sobre ellos se podrán hacer mediciones (Angeles & Gentili, 2010; IGAC, 2016; Instituto Geográfico Nacional, 2010).

Ortofotomosaico. Es la fusión de dos o más ortofotos conformando una representación continua de una superficie del terreno. Para elaborar este ortofotomosaico, se emplean una serie de técnicas, en donde algunas fotografías


aéreas correctamente posicionadas y rectificadas son unidas, y a su vez se subsana alteraciones sistemáticas tanto en radiometría como en geometría (IGAC, 2016).

Software fotogramétrico

Image Station. Se ha venido desarrollando por más de 40 años en lo que es tecnología fotogramétrica. En él se encontrarán módulos para la creación, orientación y triangulación de proyectos; además de la recopilación y edición de las características en 3 dimensiones, análisis y edición de modelos digitales del terreno, edición mediante fotograma aéreo, escáner de línea, UAV e imágenes de satélite. Brinda funciones interactivas con base en CAD/SIG, para cumplir con los requisitos organizacionales y entrega de producto a clientes. Basado en sistema operativo Windows, puede ser necesario de licencias auxiliares como MicroStation o Geomedia (Hexagon, 2021). En la figura 12, se describen los módulos de Image Station.

Figura 12.

Image Station - Módulos



Nota: Recuperado de (Hexagon, 2021).

Image Station Photogrammetric Manager (ISPM). Proporciona herramientas para la creación y gestión de proyectos necesarios para el flujo de trabajo en producción

fotogramétrica. Provee una interfaz compatible entre los paquetes de triangulación de otros software aceptados y con los productos de Image Station, para admitir la triangulación/orientación, funciones 3D, la colección de DTM y flujos de trabajo en ortofotos, entre sus principales características se tiene (Hexagon, 2021):

- Guiar proyectos, cámaras, fotos, tiras y bloques.
- Herramientas para la importación de datos UAV y satélite.
- Orientaciones (interior, relativa, absoluta).

Image Station Automatic Triangulation (ISAT). Realiza una triangulación aérea de manera automatizada, empezando desde la orientación interior hasta establecer puntos de enlace y el análisis del bloque final con entrega de parámetros de orientación. Permite seleccionar fotos y modelos, procesar datos GNNS/INS, calibración de cámara, parámetros de auto calibración, análisis gráficos y vectoriales. Además posee herramientas para la triangulación de imágenes de satélite (Hexagon, 2021).

Image Station Stereo Display (ISSD). Facilita la visualización y manipulación de imágenes aéreas y estéreo de satélite, con el seguimiento de un cursor 3D que es fotogramétricamente preciso, superposición de vectores 3D, ajuste de brillo y contraste a través del entorno gráfico de MicroStation. Además, en él se incluirá una licencia de Image Station Feature Collection (ISFC) (Hexagon, 2021).

Image Station Feature Collection (ISFC). Es una aplicación de bajo costo, pero muy versátil para la recopilación de características en los mapas. Sus herramientas nos permitirán extraer de manera interactiva la geometría y características, tanto en 2D y en 3D, además de los atributos en la interfaz de MicroStation. Todo esto hace posible el levantamiento de características a partir de un par o modelo estereoscópico (Hexagon, 2021).

Image Station Automatic Elevations (ISAE). Permite la extracción automática de puntos de elevación en un modelo digital del terreno (MDT) en imágenes estéreo. Se encuentra altamente automatizado, a través del uso de imágenes de datos jerárquicos y métodos de procesamiento de imágenes. Además, se puede integrar directamente con otros módulos como ISOP para la generación de ortofotos (Hexagon, 2021).

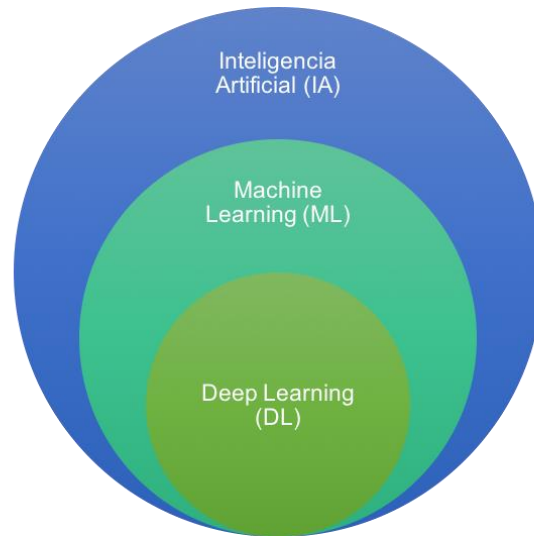
Image Station Ortho Pro (ISOP). Es un sistema de alto rendimiento en producción orto, en él se incluyen la planificación de proyectos de orto rectificación, balance de tonos, creación de mosaicos y true ortho, generación automática de seamlines (líneas de unión), evaluación de la calidad de ortofotos. Para hacer uso de este módulo será necesario una licencia de Geomedia (Hexagon, 2021).

Inteligencia artificial

Es parte de las ciencias de la computación, responsable del diseño y la construcción de sistemas que se encuentran relacionados con las actividades cognitivas humanas. Es un concepto no fácil de definir, se dice también, que el término es usado cuando una máquina es capaz de realizar funciones propias de la inteligencia de los humanos, como: el ser creativo, sensible, capacidades de aprendizaje, entender y percibir el ambiente, así como utilizar el lenguaje. Una rama que ha entrado en auge en los últimos años es el aprendizaje de máquina o Machine Learning (B. Pérez, 2018). En la figura 13, se presenta un esquema de la IA y sus ramas.

Figura 13.

Inteligencia artificial y sus ramas



Nota: Elaboración propia.

Machine Learning

Una rama de la inteligencia artificial (IA) es el Machine Learning (ML), también llamado como aprendizaje automático, trata de la incorporación de una serie de técnicas y algoritmos que son capaces de aprender, partiendo de información distinta y nueva, generando algoritmos que mejoren de manera automática, en base a la experiencia. De esta forma se puede tener métodos para la identificación autónoma de patrones en los datos y usar los mismos para hacer una predicción sobre futuros en un mundo de incertidumbre. A continuación, se citan sus componentes (Management Solutions, 2018).

- Fuentes de información.
- Técnicas y algoritmos (tratamiento de la información).
- Capacidad de aprendizaje (adaptación a cambios en los datos).
- Uso de sistemas y software (programación y visualización).

En la actualidad es muy común utilizar técnicas de Machine Learning, se han diseñado máquinas que generan conocimiento por sí mismo, tienen la capacidad de programarse automáticamente y aprender empíricamente, conjugando los datos de entrada y situaciones del mundo real. Suele subdividirse en grupos que son el aprendizaje supervisado y el aprendizaje no supervisado (Valdés & Baquero, 2019).

Aprendizaje supervisado. El objetivo es aprender la concordancia de los datos de entrada X y salida Y de forma que, cuando se dé una nueva entrada X' , la salida Y' tenga una alta precisión. La precisión puede ser descrita por una función llamada de "pérdida". En este grupo se desarrolla la técnica de Deep Learning. La finalidad es crear uno o varios modelos, a través de los cuales las máquinas generen conocimiento, partiendo de un conjunto de datos de entrada, y en el desarrollo, estos se vayan corrigiendo. En términos prácticos es dar experticia y la forma en que un cerebro procesa (Valdés & Baquero, 2019).

Aprendizaje no supervisado. Contrario al aprendizaje supervisado, aquí no se cuenta con datos iniciales de la variable que se quiere predecir. El propósito de este grupo es el de localizar patrones o relaciones en los datos. De aquí, que también se lo llama como Knowledge Discovery, que describe un proceso por el cual se establecen patrones válidos, nuevos, de gran utilidad y que se puedan entender (Management Solutions, 2018).

Deep Learning

Aprendizaje profundo desde su traducción del inglés, es un conglomerado de algoritmos que generan aprendizaje automático (Machine Learning), los mismos que tienen la intención de modelar abstracciones de nivel superior en datos, en los que se emplea arquitecturas conformadas por transformaciones no lineales múltiples. La idea

es desarrollar modelos informáticos que tengan una función parecida a la del cerebro humano (una serie de neuronas artificiales interconectadas que analizan datos). El aprendizaje profundo establece un proceso, en el que se obtienen mejores representaciones de la información analizada (el modelo no hace que la máquina aprenda, más bien es una representación en la que se modifica la forma de ver los datos) (Valdés & Baquero, 2019).


Redes neuronales artificiales. Son redes que se interconectan entre ellas de forma masiva, en paralelo de elementos simples (generalmente de adaptación) y con estructura jerárquica, éstas procuran relacionarse con objetos reales de manera similar al realizado por el sistema nervioso humano. Es descrito como una herramienta que ayuda en la solución de problemas principalmente de clasificación, como por ejemplo reconocer caracteres, palabras, voz, e incluso ayudar en la detección de enfermedades, entre sus ventajas se encuentran (Matich, 2001):

- Aprendizaje adaptativo.
- Auto-organización.
- Tolerancia a fallos.
- Operación en tiempo real.
- Vanguardia tecnológica.

En la figura 14 se evidencia el esquema de una red neuronal en el que se tiene 3 capas interconectadas, los mismos que integran la información a través de una capa de entrada, seguidamente interactúa una capa oculta y tiene los resultados a través de una capa de salida. Una neurona, al igual que la biológica, por sí misma es muy pequeña, pero al combinar miles o millones, puede resolver problemas muy complejos (Matich, 2001).

Figura 14.

Elementos de una red neuronal



Nota: Recuperado de (Matich, 2001).

Función de entrada. Una neurona procesa varios valores de entrada como si fuesen uno solo, por lo que se le llama entrada global. El problema es hacer una combinación de varias entradas en una sola, es aquí donde entra el concepto de función de entrada, la misma que está determinada por el vector de entrada multiplicada por los pesos, que modifican la influencia que tienen los valores iniciales. La función de entrada se puede establecer como (Matich, 2001):

$$input_i = (in_{i1} * w_{i1}) * (in_{i2} * w_{i2}) * \dots * (in_{in} * w_{in}) \quad (1)$$

Donde:

*: Representa el operador deseado (Max, Min Sum, Producto).



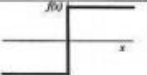
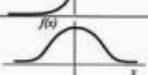

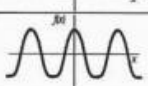
in : Número de entradas para la neurona N_i .

w_i : Peso para la neurona N_i .

Función de activación. Al igual que una neurona biológica, las neuronas artificiales pueden estar activadas (excitada) o desactivadas (no excitada). Unas tienen dos estados de activación, mientras que otras se pueden mover dentro de un dominio determinado. Esta función determina el momento de actividad en una neurona, modificando una entrada global en un valor de activación (valores entre $[0,1]$ o $[-1,1]$). La función de activación, es una función de entrada global a la que se le resta el umbral. Entre las más utilizadas se encuentra la función lineal, sigmoidea y tangente hiperbólica (Matich, 2001); como se detalla en la figura 15.

Figura 15.

Funciones de activación mayormente utilizadas

	Función	Rango	Gráfica		Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$		Sigmoidea	$y = \frac{1}{1+e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$		Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$		Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Nota: Recuperado de (Nacelle, 2009).

Función de salida. Es la función final que necesita una neurona, el resultado de esta función será el valor de salida en la neurona. Si la función de activación se encuentra por debajo del umbral establecido, no existe ninguna salida por lo que se pasa a la neurona siguiente. Por lo tanto, los valores de salida están comprometidos en el rango entre $[0,1]$ o $[-1,1]$. Las funciones de salida más comunes son identidad y binaria (Matich, 2001).

Redes neuronales convolucionales (CNN). Una de las aplicaciones más frecuentes es el reconocimiento y clasificación de imágenes, identificación de objetos,

detección de caras, entre otras. En CNN se le proporciona una imagen como entrada, ésta la procesará y clasificará de acuerdo con una serie de categorías o clases. La máquina asimila la imagen como una matriz de píxeles, y se encuentra en función de la resolución de la misma (Valdés & Baquero, 2019).

Al igual que en todas las redes neuronales, las CNN están conformadas por una capa de entrada, capa de salida y múltiples capas ocultas, lo que les diferencia, es que en las CNN se encuentra explícito que el Input son imágenes, esto permite establecer propiedades en las arquitecturas para la identificación de objetos. En las redes convolucionales se genera conocimiento en diferentes niveles de abstracción, de ahí que muchas capas determinarán la identificación de estructuras con mayor complejidad en la información de entrada. Entre los componentes de las CNN se encuentran: la convolución y pooling (Valdés & Baquero, 2019).


Convolución. Su fundamento es determinar características o rasgos visuales en las imágenes, como pueden ser líneas, curvas, aristas, etc. Una vez generado el conocimiento de una característica en un lugar específico de la imagen, esta la puede encontrar en cualquier parte de la misma. Las capas convolucionales pueden aprender mediante patrones locales, en ventanas de menor tamaño en 2D. Las capas convolucionales se desarrollan bajo tensores en 3D llamados Feature Maps, los mismos que cuentan con dos ejes espaciales (largo y ancho) y otro que denota la profundidad (número de bandas en imágenes) (Valdés & Baquero, 2019).

A medida que el Kernel va haciendo su trabajo, se tiene como resultado el filtrado de una imagen nueva, en la que se han ido escribiendo las características de la imagen inicial, esto permitirá posteriormente la distinción entre los objetos. Luego de que la convolución ha sido realizada en la imagen por medio de un filtro Kernel, es

momento de aplicar la función de activación (Valdés & Baquero, 2019). En la figura 16 se puede apreciar el funcionamiento del filtro Kernel.


Figura 16.

Kernel



Nota: Recuperado de (Valdés & Baquero, 2019).

Pooling. Este es el proceso en el que se hace una reducción en la cantidad de neuronas, previo a la realización de una nueva convolución. Esta actividad pretende reducir el tamaño de información a procesar por la máquina. Aquí se minimiza el tamaño de las imágenes que han sido filtradas, prevaleciendo las características detectadas por cada filtro. Existen diferentes tipos de pooling, el más frecuentemente es el de Max pooling, que se visualiza en la figura 17 (Valdés & Baquero, 2019).

Figura 17.*Max pooling*

Nota: Recuperado de (Valdés & Baquero, 2019).

Como se aprecia en la figura 17, el algoritmo Max pooling de un tamaño de 2x2 (en total 4 píxeles) tomará el valor más alto de estos. Resultado de este proceso, se obtiene una imagen reducida a la mitad de la original, que son significativamente menos, y prevalece la información de mayor importancia en cuanto a la detección de características (Valdés & Baquero, 2019).

TensorFlow. Es una librería de código abierto desarrollada por Google, esta es un entorno de Deep Learning. En la librería se generan y entrenan redes neuronales, las mismas que detectan correlaciones y se descubren patrones similares al aprendizaje y razonamiento en el ser humano. Esta permite un desarrollo rápido en computadores con plataformas (GPUs, CPUs, TPUs), clústeres de servidores y en dispositivos móviles. Por lo que es un aporte muy fuerte para ML y DL (Conde Ortiz, 2018; Valdés & Baquero, 2019).

TensorBoard. Es un módulo de TensorFlow, en el que se puede observar el aprendizaje. En razón de que los cálculos realizados tienen alta complejidad y confusión, para tener una mejor comprensión, depuración y la optimización de programas, se incluye una serie de herramientas que permiten su visualización por

medio de gráficos, métricas cuantitativas y otros datos adicionales. Entre las herramientas se encuentran (Valdés & Baquero, 2019):

- Seguir y visualizar métricas como pérdida y exactitud.
- Visualizar el gráfico del modelo (operaciones y capas).
- Observar histogramas de pesos y sesgo, y su cambio en el tiempo.
- Mostrar imágenes, texto, datos de audio.
- Crear perfiles de programas en TensorFlow (TensorFlow, 2018).

Software ENVI. Desarrollado por L3Harris Geospatial, es un programa especializado en el análisis digital de imágenes, cuyo objetivo es extraer información que sirva como insumo en la toma de decisiones. En la actualidad las empresas eligen ENVI, porque es compatible con una serie de sensores populares en esta época, entre las facilidades del programa tenemos (GeospaceSolutions, 2019):

- Extensible; combina las herramientas para crear nuevas capacidades de análisis de imagen.
- Integración con el entorno de ARCGIS.
- Funcionalidad con cualquier tipo de datos.
- Flujos de trabajo automatizados.

ENVI Deep Learning. L3Harris Geospatial ha implementado una tecnología de carácter comercial para Deep Learning, conformada para trabajar con imágenes satelitales, en razón de resolver problemas geoespaciales. El módulo de ENVI Deep Learning forma parte de las aplicaciones de ENVI para escritorio, por lo que podrá desarrollarse sobre computadores, servidores e incluso en la nube. En la actualidad no todo el mundo es experto en Deep Learning, por lo que este módulo incluye

herramientas y flujos de trabajo intuitivos, que no deberán ser programados (L3Harris Geospatial, 2019).

Parámetros de ENVI Deep Learning. Entrenar un modelo significa pasar rápidamente ráster etiquetados, de tal forma que con el pasar del tiempo, este aprenderá a obtener información espacial y espectral de los ráster de etiquetas, esto desencadenará en ráster de activación, el que guardará las características obtenidas en el entrenamiento. En un inicio este ráster de activación toma valores aleatorios para luego ser comparado con el ráster de etiquetas, y a través de la función de pérdida el modelo aprende en donde se equivocó, los pesos se van ajustando para mejorar el modelo (L3Harris Geospatial, 2020a).

Epoch y batch (épocas y lotes). Tradicionalmente una época es pasar una serie de datos completos en el entrenamiento, una vez. Más bien en ENVI Deep Learning los parches se toman de forma inteligente de los ráster de etiquetas, en razón de que los píxeles con mayor intensidad de características ingresan con más frecuencia en el entrenamiento. Por lo tanto, una época en ENVI, es cuantos parches se entrenan previo a que el sesgo esté ajustado. No hay un número exacto, por lo que deberán ser adecuados para que la ponderación sea sin inconvenientes. El valor sugerido está entre 10 y 30 (L3Harris Geospatial, 2020a).

Una vez establecido el número de épocas, se deberá determinar el número de parches por época, que responde a la pregunta cuánto entrenamiento se debe dar. Este valor contempla ser menor en datos pequeños y mayor en conjunto de datos grandes. El valor de sugerencia se encuentra entre 200 y 1000 pudiendo ser mucho más alto. Un lote es el número de parches que se utilizan para el entrenamiento en una iteración. El lote se desarrolla en una época, hasta lograr alcanzar el número de parches por época determinados. Se deberá establecer el número de parches en razón de la memoria

GPU disponible. En la tabla 2 se dan unos valores iniciales para determinar este valor (L3Harris Geospatial, 2020a).

Tabla 2.

Parámetros recomendados en función de la memoria gráfica (GPU)

Memoria gráfica (GPU)	Tamaño del parche	Parches por lote
16 GB	704	4
16 GB	464	9
12 GB	608	4
12 GB	464	7
8 GB	672	2
8 GB	464	4
4 GB	464	2
4 GB	320	4
2 GB	464	1
2GB	224	2

Nota: Recuperado de (L3Harris Geospatial, 2020a).

Class weighth. ENVI propone un sesgo en el modelo, con la finalidad de que se vea con mayor frecuencia aquellos parches que tienen mayor densidad de píxeles característicos, la técnica utilizada se llama Inverse transform sampling. El parámetro que controla este sesgo es Class weighth que establece valores mínimos y máximos, siendo el máximo utilizado al inicio del entrenamiento y llegando al mínimo al final del mismo. El valor mínimo a menudo es 0, y para establecer el valor máximo se toma en

cuenta que se dan mejores resultados cuando la proporción de ejemplares positivos con negativos está entre 1:100 (L3Harris Geospatial, 2020a).

Loss weight. Es utilizado para sesgar la función de pérdida y enfatizar la búsqueda correcta de píxeles característicos en lugar de píxeles de fondo. Es conveniente cuando las características son muy pocas o cuando no se han etiquetado todas las características. Su rango es $[0,1]$, cuando es 0 se tratará los píxeles de fondo y característica de la misma forma, cuando aumenta, se inclinará la función hacia la búsqueda de píxeles característicos, el valor predeterminado es de 0.8 (L3Harris Geospatial, 2020a).

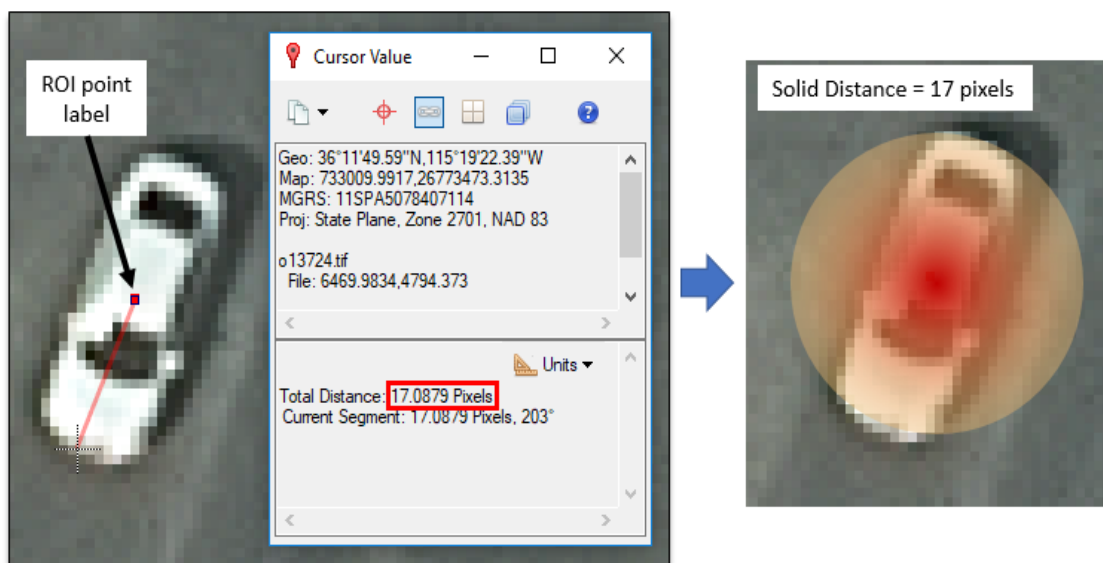
Patch sampling rate. Permite indicar la densidad del muestreo que debe producirse, está definido como el número promedio de parches a los que corresponderá cada pixel, en el ráster de entrenamiento y validación. El valor predeterminado es de 16, pero este valor deberá aumentar cuanto las características son escasas, generando una mayor probabilidad de que se escojan suficientes parches que contengan las características. La única razón por la que se disminuirá este valor es cuando existe una alta densidad de características y no existe la necesidad de cubrir cada píxel, finalmente disminuirá el tiempo de procesamiento (L3Harris Geospatial, 2020a).

Solid distance y Blur distance. Muchas veces el proceso de etiquetar ráster es tedioso, por lo que se puede utilizar las herramientas como punto y polilínea para realizar este proceso. El parámetro distancia sólida, es la cantidad de píxeles que rodean a las etiquetas en todas las direcciones, a manera de buffer. Por otro lado, los algoritmos de Deep Learning tienen problemas para aprender los bordes afilados, el parámetro Blur distance permite desenfocar los bordes, ayudando al modelo a enfocarse de manera gradual. Al inicio la entidad se extiende hasta la distancia de desenfoco máxima, reduciéndose al valor mínimo conforme avanza el entrenamiento.

El valor mínimo deberá ser 0 para las clases que contengan bordes bien definidos (L3Harris Geospatial, 2020a). En la figura 18, se ilustra el parámetro solid distance.

Figura 18.

Solid Distance (Distancia sólida)



Nota: Recuperado de (L3Harris Geospatial, 2020a).


Métricas del entrenamiento. ENVI Deep Learning utiliza la plataforma TensorBoard para evaluar el rendimiento de los entrenamientos, dando a conocer los metadatos de los mismos, esta opción proporciona información detallada sobre las métricas de precisión en tiempo real sobre los modelos entrenados. Cuando comienza el entrenamiento TensorBoard desplegará gráficos en temas de: pérdidas, precisión, exactitud y recuperación (L3Harris Geospatial, 2020b).

Loss. Es un número adimensional, que proporciona información de que tan cerca se ajusta el clasificador entre los datos de entrenamiento con los de validación. Cuando el número es 0 quiere decir que el ajuste es perfecto, cuando este valor se aleja de 0 el ajuste va perdiendo precisión. TensorBoard muestra gráficos para lotes completados en cada época, así como para épocas completas. Los gráficos

denominados `epoch_loss` y `epoch_val_loss`, disminuirán progresivamente en las primeras épocas llegando a converger a 0. En la figura 19 se indica los valores de pérdida en validación, el valor más bajo se tiene en la época 8 por lo que se podría terminar el proceso de entrenamiento, de la misma forma, los pesos se van ajustando con cada época, por lo que cuando se obtenga el valor mínimo en pérdida, ENVI guardará la información sobre los pesos para utilizarlos posteriormente (L3Harris Geospatial, 2020b).

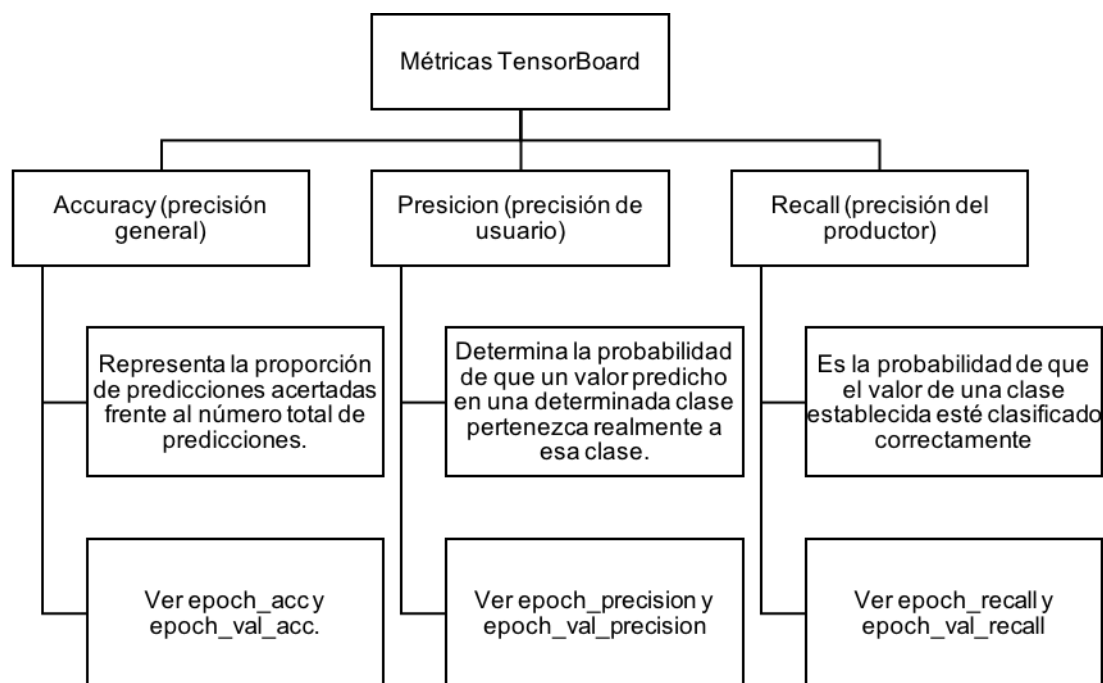
Figura 19.

Ejemplo de valores de pérdida de validación



Nota: Recuperado de (L3Harris Geospatial, 2020b).

TensorBoard también proporciona información sobre otras métricas, que se detallan en la figura 20.

Figura 20.*Métricas TensorBoard*

Nota: Recuperado de (L3Harris Geospacial, 2020b).

Digitalización

Es el proceso, a través del cual partiendo de una imagen y la utilización de un programa especializado (SIG), se obtiene información de tipo vector. Por otro lado, también es el trazo y catalogación de los objetos geográficos que se consideren fotografiables, con el objetivo de permitir consultas y visualizar la información. Es el proceso de mayor utilidad para la automatización de los datos espaciales, aquí será de gran importancia la capacidad de analizar por parte del operador y la toma de decisiones será flexible y adaptable a las circunstancias del caso (Felicísimo, 1994; IGM, 2013).

Vectorización

Es el método mediante el cual los píxeles adyacentes se conforman, de tal manera que se constituyen en líneas, dando origen a una imagen vectorial. Su relación con el mapa original se encuentra basado en la calidad gráfica y su complejidad, pudiendo ser un producto con bajo nivel de depuración, en razón de las dificultades al momento de separar las líneas de nivel con respecto a otras capas como son la toponimia, cotas, carretera, red hidrográfica, entre otras (Felicísimo, 1994).

Generalización

Se considera como el proceso, mediante el cual expresamos una idea de forma resumida, con el objetivo que ésta sea comprensible y pueda ser aprovechada al máximo posible. En cartografía este término significa representar un dato geográfico en una escala menor, sin perder los detalles que poseen. La Asociación Internacional de Cartografía para 1973, la define como la extracción y representación resumida de detalles, en función de la escala y la finalidad del mapa. Existen diversos factores que pueden afectar en la tarea de generalización, que se detallan a continuación (Instituto Geográfico Nacional, 2014; Olaya, 2014):

- Escala: una parte primordial en este proceso, afecta en la cantidad de elementos que se deberán representar y en sus dimensiones, una escala menor significa un mayor trabajo de generalización.
- Finalidad del mapa: este factor establece los elementos que han de ser suprimidos, y a su vez cuales deberán resaltar en el mapa. Este proceso se encontrará en función del público, al que se dirija el mapa e incluso la utilidad que se le dará al mismo.

- Fuentes de datos: es muy común que al momento de realizar un mapa se deba integrar diversas fuentes de información con diferentes escalas y con calidad distinta, por lo que es indispensable la homogenización de la información inicial.
- Simbología: conforme la escala va disminuyendo, los elementos aumentan el grado de simbolización, esto requiere de una mayor atención al momento de diseñar y ubicar los signos para no eliminar las características y la legibilidad de los elementos.

Operaciones de generalización. Para desarrollar un proceso de generalización se deben tomar en cuenta las siguientes operaciones (Instituto Geográfico Nacional, 2014):

- Selección / eliminación: al momento de realizar un cambio de escala del mapa, surgirán elementos que se deberán incluir y otros que se han de suprimir, en tal sentido, se escogerán algoritmos de selección y eliminación sistemática, que podrán estar basados en longitudes y áreas mínimas, atributos gráficos. Los criterios a aplicarse deben tener un carácter cualitativo y cuantitativo (Instituto Geográfico Nacional, 2014).
- Simplificación: aquí se detalla el método de minimización de puntos a lo largo de un objeto lineal o en el perímetro de un objeto poligonal, con el objetivo de facilitar su representación conservando su aspecto visual. Se crearán objetos más sencillos que reemplazarán a los originales manteniendo sus características visuales (Instituto Geográfico Nacional, 2014; Olaya, 2014).
- Tipificación/clasificación: es minimizar la complejidad de una serie de elementos, a través de su representación en un número más pequeño de

rasgos significativos, tanto en su aspecto como en su distribución relativa (Instituto Geográfico Nacional, 2014).

- **Agregación:** es el reemplazo de un conglomerado de objetos por uno con un menor número de objetos, aquí se crearán objetos poligonales que se muestren de manera eficaz (Instituto Geográfico Nacional, 2014).
- **Colapso:** considerado como el método por el cual se cambia la dimensión en elementos establecidos, con la finalidad de reducir el área que estos ocupan, un ejemplo clásico es cuando un río de tipo polígono pasa a ser una sola línea (Instituto Geográfico Nacional, 2014).
- **Exageración:** en algunos casos, conservar el objeto en su propia escala, desencadenaría en que no se puedan evidenciar las características del mismo. La solución a este problema será la exageración en el tamaño del elemento para facilitar su interpretación y no perder información (Olaya, 2014).
- **Desplazamiento:** es la representación de un elemento en una posición diferente a la que le correspondería en el terreno, con el objetivo de garantizar su visualización y tener un resultado más claro (Olaya, 2014).

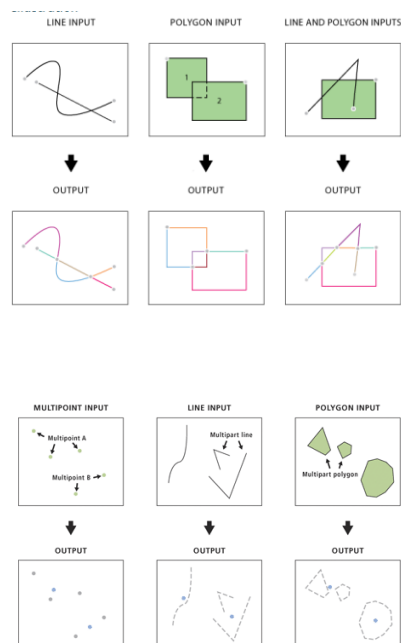
Herramientas de generalización. En la tabla 3 se detallan una serie de herramientas que ayudan en el proceso de generalización (ESRI, 2016):

Tabla 3.


Herramientas de generalización

HERRAMIENTA	DESCRIPCIÓN	ILUSTRACIÓN
-------------	-------------	-------------


- Feature to Line** Sirve para convertir elementos tipo polígono en tipo línea, guardando sus caracteres. El archivo creado muestra el perímetro del elemento poligonal original.
- Feature to Point** Sirve para generar un shape adicional tipo punto y guarda atributos del elemento original, también crea un centroide, el mismo que corresponde al punto de equilibrio del elemento.



- Simplify Line** Sirve para resumir los elementos, usando una tolerancia de desplazamiento. Se resumirán los vértices dependiendo del algoritmo usado. Se recomienda usar Bend Simplify.



- Buffer** Sirve para establecer polígonos de zona de influencia, alrededor de entidades de entrada a una distancia descrita.



Nota: Recuperado de (ESRI, 2016).

Topología

Es la parte de la matemática que se dedica al estudio de aquellas propiedades de los objetos espaciales, que se encuentran relacionados y que permanecen sin variar a pesar de que el mapa tenga distorsiones, cambios de escala, proyecciones, alargamientos o reducciones. Su finalidad es dar origen a objetos de orden superior, además de eliminar errores que no son observables ante el ojo humano (Sarría, 2015).

La topología necesita de archivos de datos extra, para guardar las relaciones espaciales; la importancia radica en la seguridad de que la información generada es de calidad y permite la integridad de los mismos. Por otro lado, el estructurar topológicamente las capas, permitirá la ejecución de análisis en SIG, incluyendo tareas de consulta y búsqueda (Chang, 2019).

Reglas topológicas. Están definidas dentro de una base de datos geográfica y el usuario elige las reglas que se aplicaran a una serie de capas. Algunas reglas se han de aplicar en una capa, mientras que otras podrán ser combinadas entre dos o más capas. Las reglas topológicas a aplicarse estarán en función de la geometría de la capa, pudiendo ser éstas de tipo puntual, lineal o poligonal. En la tabla 4 se resumen las reglas topológicas más utilizadas para el programa ArcGIS 10.5 (Chang, 2019).

Tabla 4.

Reglas topológicas en ArcGIS 10.5

Tipo de geometría	Reglas
Polígono	must not overlap (no debe superponerse), must not have gaps (no debe tener huecos o espacios), must be covered by (debe estar cubierto por), contains point (contiene los puntos).

Línea	must not overlap (no debe superponerse), must not intersect (no debe intersecarse o cruzarse), must not have dangles (no debe tener colgantes o extremos sueltos), must not have pseudo-nodes (no debe tener pseudo nodos), must not intersect or touch interior (no debe cruzar o tocar el interior).
Punto	Must be coincident with (debe coincidir con), must be covered by boundary of (debe estar cubierto por el límite de).

Nota: Recuperado de (Chang, 2019).

GNSS

Global Navigation Satellite System, es el término general que contiene a todos los Sistemas de Navegación por Satélite, brindan información sobre el posicionamiento y navegación, cubriendo toda la Tierra, en manera autónoma, así como con la incorporación de sistemas de aumentación. También se considera como la infraestructura en el espacio de satélites, que generan señales para que los usuarios a través de un receptor compatible, determinen su posición, velocidad y tiempo. Entre las señales GNSS se encuentran GPS, GLONASS, GALILEO y BeiDou (Berné et al., 2019).


Los GNSS están conformados por tres segmentos: segmento espacial, se encuentra integrado por una serie de satélites que contienen un reloj de alta precisión y a su vez emiten señales de radio; segmento de control, compuesta por estaciones que monitorean y controlan los satélites; y finalmente el usuario en los que se encuentran todos los receptores que determinan la ubicación de un cliente final (García, 2017).

Métodos de posicionamiento. Se han desarrollado diferentes métodos de posicionamiento GNSS, con el objetivo de determinar posición con la mayor precisión posible, mayor rapidez, y economizando lo máximo posible. Existen diversas maneras de clasificarlos como, por ejemplo: sistema de referencia, movimiento de aparato

receptor, método para la obtención de coordenadas, entre otras. En la figura 21 se esquematiza la clasificación mayormente utilizada (Buitrón, 2009; González, 2015).

Figura 21.

Tipos de posicionamiento GNSS



Nota: Recuperado de Universidad de Cádiz (2009), como se citó en (Chuquitarco, 2018).

Posicionamiento absoluto. es cuando se calcula la localización de un punto tomando en cuenta medidas de pseudodistancia, pudiendo ser de código C/A o P, su precisión se encuentra alrededor de los 15 hasta 100 m, es muy común en equipos navegadores y con la eliminación de la disponibilidad selectiva pueden tener precisiones entre 3-5 m en tiempo real (Peñafiel & Zayas, 2001).

Posicionamiento relativo. Es cuando intervienen dos o más receptores, con el objetivo de suprimir errores propios del sistema, calculando coordenadas desde un equipo de referencia hasta otro llamado móvil. Las coordenadas del equipo de referencia serán conocidas con anterioridad y para las del móvil se necesitará de un post-proceso. En este posicionamiento los errores serán comunes en ambos puntos (Peñafiel & Zayas, 2001).

Estático. Utilizado para distancias mayores (> 20 km), con la finalidad de obtener una precisión muy alta (en el orden de los milímetros). Se trata de posicionar dos o más receptores en los puntos de los que vamos a obtener sus coordenadas, se guardan los datos para luego post-procesar sus coordenadas. Se obtendrán tantas soluciones como se deseen, por lo que su tiempo de observación es prolongado. Sus aplicaciones son el control geodésico, redes nacionales como internacionales, monitoreo de movimientos tectónicos, deformaciones en estructuras (Peñafiel & Zayas, 2001).

Estático rápido. Es una variación del método estático, aplicable para distancias menores a 20 km entre el receptor base y el móvil. El tiempo de observación puede ser entre 5 hasta 20 min, pudiendo alcanzar precisiones entre 5 y 10 mm. Se utiliza para apoyo fotogramétrico, determinación y densificación de puntos de control, redes topográficas locales, entre otras (Peñafiel & Zayas, 2001).

Rtk (Real Time Kinematic). Se trata de la obtención de coordenadas en tiempo real en un sistema de referencia determinado. Este método reemplaza a métodos tradicionales de medición, su precisión alcanza el $1 \text{ cm} \pm 2\text{ppm}$. El método consta de un receptor base recibiendo información de los satélites y enviando datos por radio al receptor móvil, que también buscará información satelital a la vista, establece ambigüedades comunes entre satélites, para lograr calcular coordenadas de su posición (Peñafiel & Zayas, 2001).

Ntrip. Es enviar correcciones diferenciales de GNSS, inicialmente en formato común RTCM, mediante el protocolo de transferencia de datos de hipertexto (HTTP), las mismas que son calculadas en una estación base y ofertadas a los consumidores por medio del internet. Se compone de NTRIP Source, es quien genera las correcciones en RTCM por medio de un receptor GNSS, para luego enviarlas a un servidor por

HTTP. NTRIP Caster, es considerado como el agente transmisor, capaz de difundir las correcciones calculadas a los consumidores. NTRIP Client, que es el receptor de las correcciones, quien las utiliza para obtener su posición en tiempo real de forma precisa (Briceño et al., 2009).

Control de calidad

Calidad

Según la norma ISO 9000 como se citó en (IDECA, 2015), está definida como el nivel en el que una serie de características inherentes satisface los requisitos, tomando en cuenta al requisito como la necesidad o expectativa establecida, pudiendo ser implícita u obligatoria. En tal sentido, la calidad se encuentra definida por la capacidad en la que se puede satisfacer a los clientes, además del impacto previsto y no previsto entre las partes interesadas (Chicaiza, 2017).

Calidad de datos geográficos. En el segmento de la información geográfica, la calidad tiene importancia en la utilidad que se le dé a los datos y confianza que presenten las fuentes de información. Esta calidad establece el grado en el que las características de un dato geográfico, satisface los requisitos que se establecieron previamente a través de una especificación técnica (IDECA, 2015).

Norma ISO 19157:2013. En ésta se describe la calidad de datos geográficos, aquí se precisan los componentes que la conforman, se detalla la agrupación y estructura de los registros, en razón de medirlos; determina procedimientos generales para calificar e informar la calidad de datos geográficos (Guinea, 2014). A continuación, en la tabla 5, se detallan los elementos y subelementos que definen la calidad de la información geográfica.

Tabla 5.*Elementos de calidad norma ISO 19157:2013*

Elementos	Subelementos
<p>Totalidad: establece la presencia o ausencia de los objetos, atributos y relaciones de un producto en referencia a su especificación técnica.</p>	<p>Comisión: se encuentra determinado como la superabundancia de datos de un producto en conformidad con su especificación técnica.</p> <p>Omisión: es la ausencia de datos en un producto, en conformidad con lo determinado en su especificación técnica.</p>
<p>Consistencia lógica: es el grado de incertidumbre con el que un producto en especial cumple con las especificaciones en cuanto a estructura interna, reglas topológicas, atributos y relaciones se refiere.</p>	<p>Consistencia conceptual: apego a las reglas definidas en un esquema conceptual, con el fin de asegurar su invariabilidad durante el proceso.</p> <p>Consistencia de dominio: lealtad de los valores con respecto a los de dominio, definidos en la especificación técnica.</p> <p>Consistencia de formato: nivel en el que los datos se encuentran almacenados en conformidad con el diseño del producto.</p> <p>Consistencia topológica: examinación de las características topológicas que se encuentran definidas.</p>
<p>Exactitud posicional: es el grado de exactitud en cuanto a posición de los objetos geográficos del</p>	<p>Exactitud absoluta o externa: exactitud posicional de un elemento en relación con un sistema de referencia.</p>

producto, en relación con sus posiciones asumidas como verdaderas. Deberán ser de tipo horizontal, vertical y en unidades del sistema de referencia adoptado.

Exactitud temporal: establece el grado de realidad en cuanto al tiempo de los elementos que se encuentran en la base de datos y las relaciones temporales en cuanto a las especificaciones del producto.

Exactitud temática: especifica el grado de fidelidad de los valores en los atributos tomados en relación con la verdadera característica en el mundo real, la clasificación exacta de los objetos y sus relaciones de conformidad con las especificaciones del producto.

Exactitud relativa o interna: es la posición de un elemento con referencia a la posición de los demás elementos del conjunto de datos.

Exactitud de posición de datos de celdas: cercanía del valor de un píxel con respecto a la posición considerada como verdadera.

Exactitud en la medición del tiempo: fidelidad de las referencias temporales de un ítem.

Consistencia temporal: franqueza de eventos ordenados o secuenciados, en caso de que estén reportados.

Validez temporal: vigencia de los datos en relación al tiempo (en conformidad con las especificaciones del producto)

Exactitud de clasificación: equiparación entre las clases establecidas a los objetos o atributos con respecto al universo de discurso.

Exactitud de un atributo cualitativo: disimilitud entre los valores dados con respecto a los valores considerados como verdaderos.

Exactitud de un atributo cuantitativo: disconformidad entre valores dados a atributos cuantitativos en relación a los valores considerados como verdaderos.

Nota: Recuperado de (IDECA, 2019).

Norma NSSDA. Conocida como el Estándar Nacional para la Exactitud de Datos Espaciales, en el que verifica la exactitud de los datos geográficos, tanto en la

componente horizontal como en vertical, tomando en cuenta el error cuadrático medio (RMSE), en conformidad con un determinado nivel de confianza, teniendo como resultado el índice de calidad en unidades del terreno. Para la evaluación de las componentes horizontales X e Y se la realizará a través de las siguientes ecuaciones (FGDC, 1998).

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

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

En donde:

- x_{carto_i} y y_{carto_i} , son coordenadas obtenidas en la cartografía.
- x_{obs_i} y y_{obs_i} , son coordenadas de chequeo observadas en campo.
- n , es el número de puntos a ser evaluados.
- i , es un número entero entre 1 y n .

Para evaluar la componente posicional para XY se la realiza a través de la siguiente ecuación (4):

$$RMSE_r = \sqrt{\frac{\sum(x_{carto_i} - x_{obs_i})^2 + \sum(y_{carto_i} - y_{obs_i})^2}{n}} \quad (4)$$

Para el 95% de nivel de confianza, se tiene dos casos:

- Caso 1: cuando $RMSE_x = RMSE_y$ la exactitud posicional se calcula con la ecuación (5)

$$\text{Exactitud } r = 1.7308(RMSE_r) \quad (5)$$

- Caso 2: si $RMSE_x \neq RMSE_y$ se aplica la ecuación (6):

$$\text{Exactitud } r = 2.4477 \times 0.5 \times (RMSE_x + RMSE_y) \quad (6)$$

Por último, para la componente Z se emplea la ecuación (7) que se muestra a continuación:

$$RMSE_z = \sqrt{\frac{\sum(z_{carto_i} - z_{obs_i})^2}{n}} \quad (7)$$

Y la exactitud para un nivel de confianza del 95%, se calcula con la ecuación (8):

$$\text{Exactitud}_v = 1,96 * RMSE_z \quad (8)$$

Tamaño de la muestra en exactitud posicional. El número de puntos a muestrear en exactitud posicional asumen una distribución de tipo normal, para lo cual se han planteado una serie de soluciones en base a diferentes normas como por ejemplo la NMAS, EMAS, NSSDA. Para la ASPRS (Positional Accuracy Standards for Digital Geospatial Data) estos puntos varían en función del área de trabajo de acuerdo con la tabla 6 (Chuquitarco, 2018).

Tabla 6.

Tamaño de la muestra en función del área del proyecto

Área del proyecto [km ²]	Número de puntos de control 2D / 3D
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

Nota: Recuperado de (Chuquitarco, 2018).

Normativa IGM

Precisión de los GCP. Estos deberán ser de mayor precisión que la cartografía que se ha de generar, de acuerdo con (IGM, 2006), viene dada por la siguiente ecuación.

$$PH_{GCP} = 0,01 \text{ cm} * M \quad (9)$$

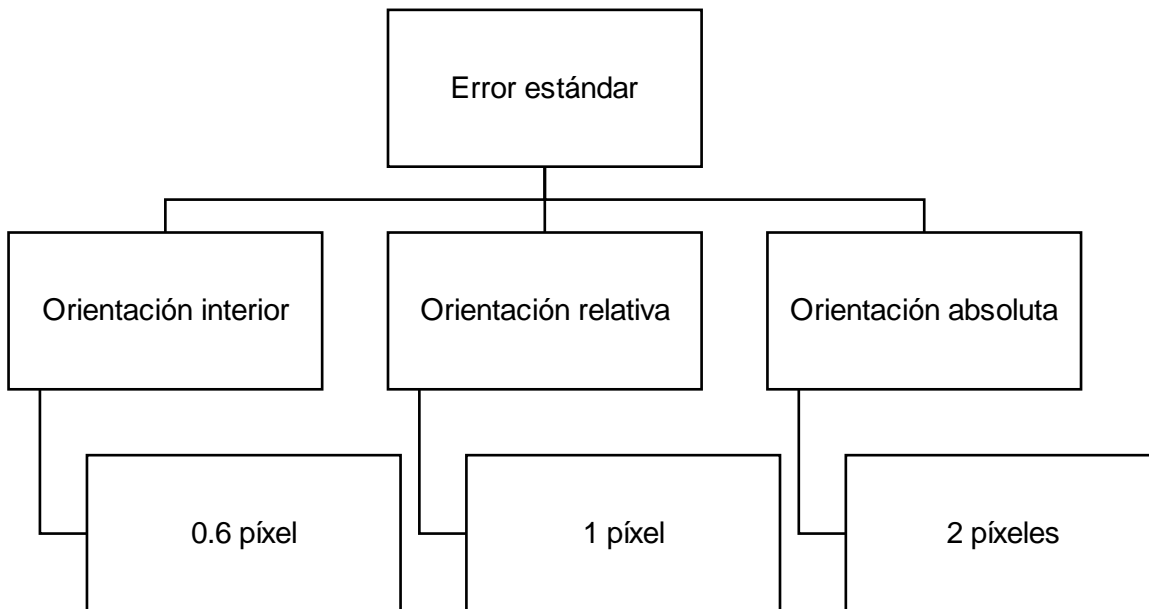
Donde:

- PH_{GCP} : Precisión de los puntos de control.
- M : Módulo de la escala.

Ajuste fotogramétrico. Según (IGM, 2006), el ajuste fotogramétrico se encontrará en función del píxel, como se detalla en la figura 22.

Figura 22.

Error estándar en ajuste fotogramétrico



Nota: Recuperado de (IGM, 2006).

Calidad de imágenes. Se deberá realizar un control radiométrico en el que se analice el histograma y en sus extremos no supere el 0.5% de saturación (IGM, 2006).

Calidad en restitución. En lo referente a planimetría, el 90% de los puntos no deberán variar de su posición verdadera de acuerdo con la ecuación (10) y en altimetría las cotas del 90% se referirán a la ecuación (11) (IGM, 2006).

$$P_H = 0,2 \text{ mm} * M \quad (10)$$

$$P_V = \frac{1}{10} * ICN \quad (11)$$

En donde:

- M : Denominador de la escala.

- *ICN*: Intervalo de curva de nivel.

Considerando que el intervalo de curva para escalas grandes dependerá de la ecuación (12):

$$ICN = \frac{M}{1000} [m] \quad (12)$$

Exactitud posicional. Para fiscalización de proyectos, el test a emplear será el de la agencia federal de los Estado Unidos, descrito anteriormente “Norma NSSDA”, en el que se menciona que los puntos obtenidos en oficina no deberán diferir del valor verdadero en un 90%, indicando 2 casos (IGM, 2018):

- Caso 1: cuando $RMSE_x = RMSE_y$ la exactitud posicional al 95% de confianza se calcula con la ecuación (13)

$$Exactitud_r = 1,5175 * RMSE_r \quad (13)$$

- Caso 2: si $RMSE_x \neq RMSE_y$ y se emplea la ecuación al 95% de confianza (14)

$$Exactitud_r = 2,1460 * 0,5 * (RMSE_x + RMSE_y) \quad (14)$$

Para la componente Z, se aplicará la siguiente ecuación (15):

$$Exactitud_v = 1,96 * RMSE_z \quad (15)$$

Precisión final. Se establece que el 95% de los puntos en el mapa estará dada por la ecuación (16), y en cuanto a altimetría el 90% se referirá a la ecuación (17) (IGM, 2016).

$$P_H = 0,3mm * denominador de la escala \quad (16)$$

$$P_V = \frac{1}{4} * \text{Intervalo de curva de nivel} \quad (17)$$

Donde:

P_H : Precisión horizontal

P_V : Precisión vertical

Estadísticos

Población. Se encuentra definida como la conformación de todos los elementos, que intervienen en el fenómeno a ser estudiado, deberán ser bien definidos, delimitados y de fácil acceso. Estos pueden ser objetos, personas, organismos, etc. (Díaz de León, 2015) (J. Arias et al., 2016).

Muestra. Es un subconjunto representativo de la población, en ella se harán las investigaciones. Para determinar la cantidad de elementos que conforman una muestra existen una serie de fórmulas (P. L. López, 2004).

Media. Es un valor representativo de todos los entes de la muestra, en otras palabras es el promedio numérico de las observaciones (Miranda et al., 2006).

Desviación estándar. Es la raíz cuadrada de la media aritmética de las desviaciones de la media, elevadas al cuadrado (Lind et al., 2012).

Nivel de confianza. Es el grado de probabilidad, con el que se desea realizar la apreciación de un parámetro a través de un estadístico muestral, generalmente se lo expresa como porcentaje. Entre los más utilizados se encuentran al 95% y al 99% (M. Arias, 2013).

Error cuadrático medio (RMS). Es definida como la raíz cuadrada del error que supuestamente se ha cometido en cada una de las medidas, dividido para el número de medidas realizadas (G. Pérez, 2012).

Sigma Naught. Es un valor que se obtiene como resultado del ajuste fotogramétrico, su valor deberá ser menor a 1/5 píxel. Un valor mayor indica que el bloque se encuentra suelto, por lo que se deberá tener cuidado con los resultados (Ibérica, 2018).

Capítulo III

Metodología

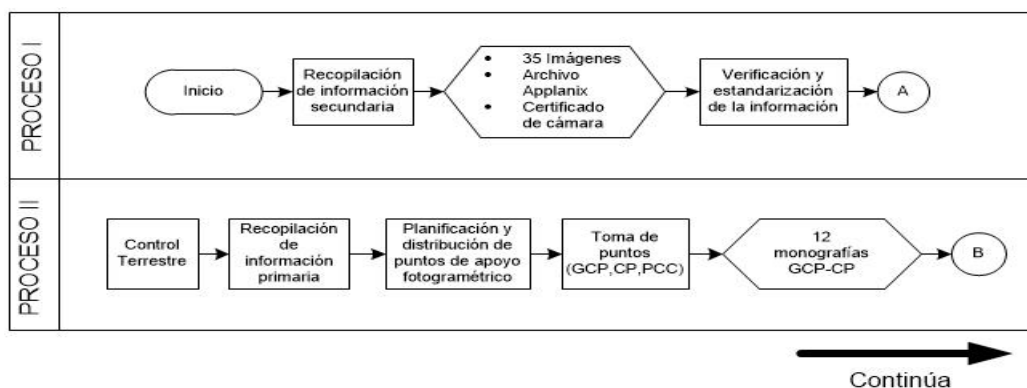
En este capítulo se detalla la metodología utilizada para realización del proyecto, empezando por la recopilación de la información, toma de puntos de apoyo fotogramétrico, ajuste fotogramétrico, restitución, Deep Learning, catalogación, y sus productos, control de calidad de datos, finalizando en la determinación de costos y tiempo.


Generalidades

La presente investigación plantea generar, analizar y comparar la elaboración de cartografía por distintas técnicas (restitución, digitalización, Deep Learning). Empezando por la obtención de la información, generación de insumos (ajuste fotogramétrico, ortofotomosaico), producción de cartografía, topología y catalogación, así como la verificación de la calidad de estas, a través de la norma ISO 19157 y exactitud posicional por medio de la norma NSSDA. Finalmente, se plantea una comparativa en temas de costos y tiempo. En la figura 23, se muestra el flujo de procesos seguido en la investigación.

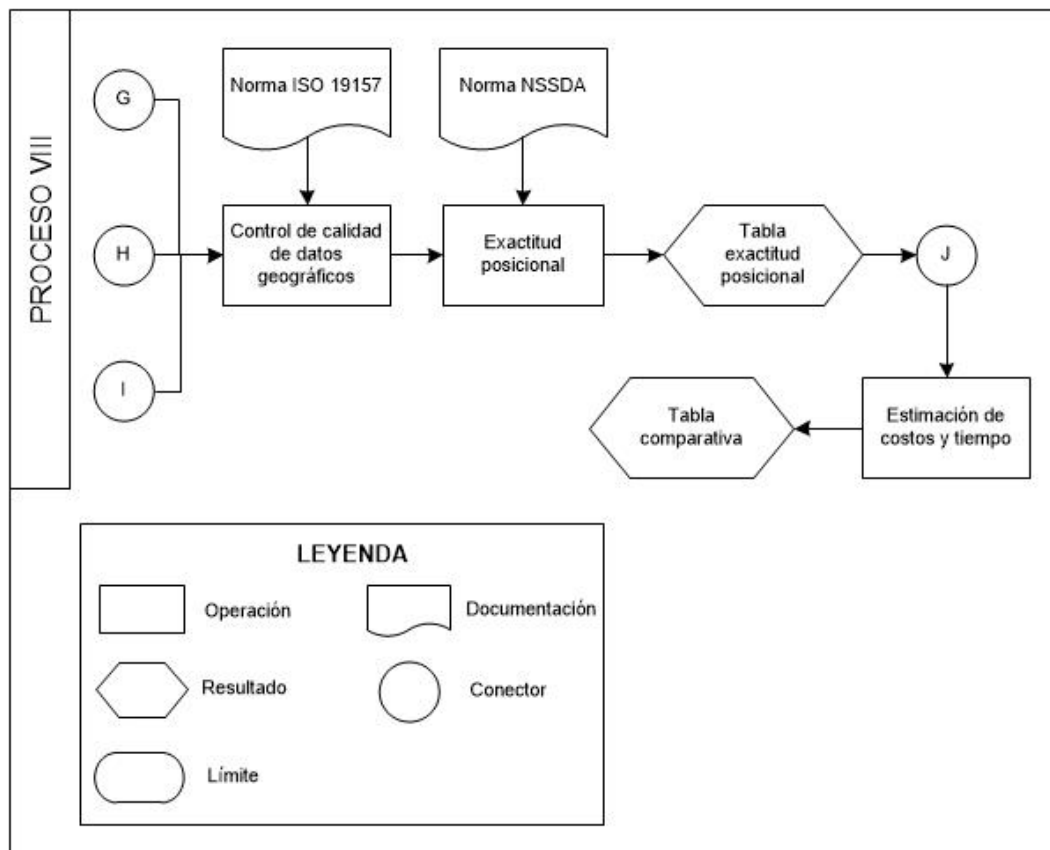
Figura 23.

Esquema general de la metodología seguida





➔
Continúa



Recopilación de la información secundaria

La Universidad de las Fuerzas Armadas – ESPE con el afán de mejorar la transferencia de conocimientos a sus estudiantes, ha generado convenios con una serie de instituciones con la finalidad de obtener insumos para la realización de investigaciones. El Instituto Geográfico Militar es el ente rector de la Cartografía Nacional que se mantiene a la vanguardia tecnológica para el desarrollo de sus procesos; por lo tanto, los insumos como: fotografía aérea, IMU/GPS (APPLANIX), información de la cámara, entre otros; han sido proporcionados por el Instituto debido al convenio marco existente entre las dos partes.

Fotografía aérea

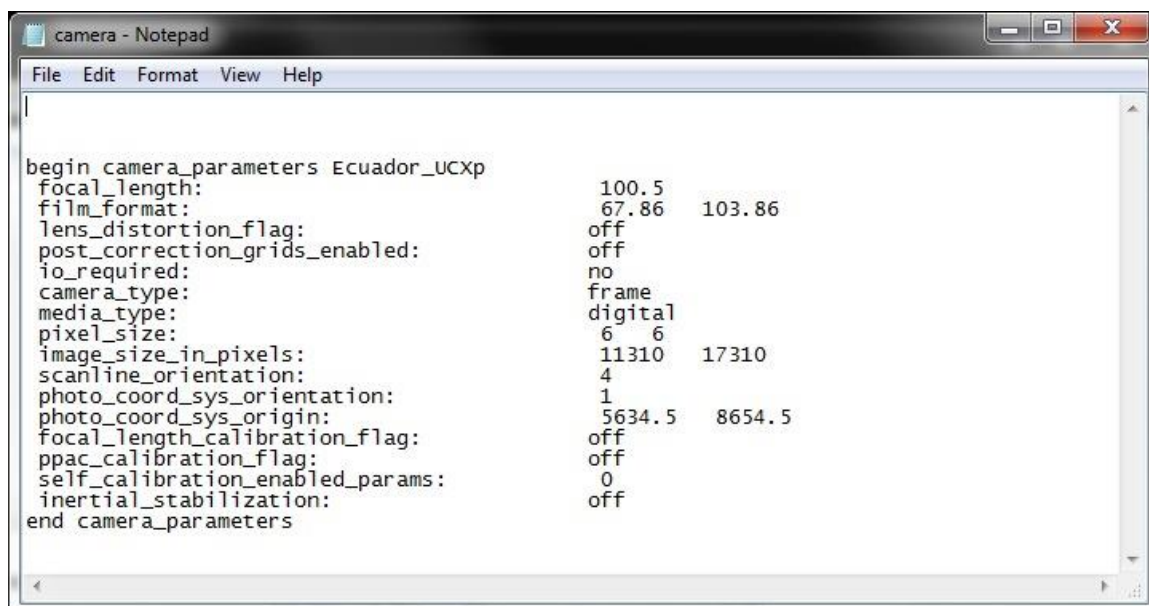
En la realización del proyecto se obtienen un total de 35 fotografías aéreas, con fecha de toma entre el 25 y 26 de junio de 2019 como parte del proyecto multiescala y de la hoja ALANGASI, tomadas por la cámara Vexcel UltraCam XP presente en el avión fotogramétrico Cessna Citation, en las bandas R, G, B, IR, con un tamaño de píxel expresado en GSD de 20 cm, conformadas por las líneas de vuelo 4, 5, 6, 7 y 8, respectivamente.

Parámetros de la cámara UltraCam XP

Por medio del certificado de calibración utilizado en la toma, se establecen los siguientes valores: focal de 100.5 mm, tamaño de píxel en el sensor (CCD) de 6 μ m, formato de (11310 x 17310) píxeles. Para el caso de esta cámara y según el certificado de calibración, las distorsiones no son ingresadas en el proceso. En la figura 24 se exponen los parámetros de cámara ingresados en el proyecto de aerotriangulación.

Figura 24.

Parámetros de la cámara



```

begin camera_parameters Ecuador_UCXp
focal_length:          100.5
film_format:          67.86  103.86
lens_distortion_flag:  off
post_correction_grids_enabled:  off
io_required:          no
camera_type:          frame
media_type:           digital
pixel_size:           6 6
image_size_in_pixels: 11310 17310
scanline_orientation: 4
photo_coord_sys_orientation: 1
photo_coord_sys_origin: 5634.5 8654.5
focal_length_calibration_flag:  off
ppac_calibration_flag:  off
self_calibration_enabled_params:  0
inertial_stabilization:  off
end camera_parameters

```

APPLANIX

Se obtienen los archivos APPLANIX, de las dos fechas de toma, en el que se encuentran los metadatos de las fotografías, como son: versión, path, características de la toma, sistema de referencia, coordenadas de los centros de exposición, ángulos de rotación, altura ortométrica, línea de vuelo, entre otros.

En este insumo se realiza un proceso de edición y estandarización, de tal forma que se tenga un archivo ordenado para posteriormente ser ingresado en el software Image Station Automatic Triangulation (ISAT). Las modificaciones realizadas son: dirección (path) de las imágenes, conversión de alturas de vuelo (de altura ortométrica a través del modelo EGM 96 a altura elipsoidal en WGS84). En la figura 25 se muestra un ejemplo del archivo depurado.

Figura 25.

Insumo archivo APPLANIX

File	Edit	Format	View	Help					
126_4	4	234064.19257	783322.571	9960344.081	5953.144	1.12956	0.0618	91.46553	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\126_4.tif
127_4	4	234068.906552	783322.705	9961022.681	5952.739	0.82642	-1.04971	91.54625	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
128_4	4	234073.61354	783322.001	9961701.397	5950.129	0.944	-0.01283	91.50926	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
129_4	4	234078.315008	783322.369	9962380.323	5949.668	1.14338	-1.15135	91.80888	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
130_4	4	234083.008648	783320.818	9962058.162	5951.766	1.39218	-1.02887	92.18254	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
131_4	4	234087.715543	783316.145	9963737.224	5954.539	1.26082	-1.96092	92.49465	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
132_4	4	234092.418537	783307.905	9964415.057	5957.879	1.44136	1.94515	92.3481	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\132_4.tif
165_5	5	234505.402118	785118.006	9964385.443	5915.354	-1.03248	-1.56532	-91.33725	D:\PROYECTO_ALANGASI\IMG_ZONA_E
166_5	5	234510.483427	785117.415	9963707.5	5917.75	-1.13769	-0.96165	-91.31694	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
167_5	5	234515.574589	785116.982	9963029.121	5920.025	-1.14316	0.22961	-91.13719	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
168_5	5	234520.671674	785119.269	9962350.758	5920.503	-1.02162	-0.31064	-90.97427	D:\PROYECTO_ALANGASI\IMG_ZONA_E
169_5	5	234525.773784	785121.738	9964394.582	5935.937	-1.00905	0.36153	-90.97876	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
170_5	5	234530.869418	785127.466	9960994.307	5919.698	-0.77231	1.53454	-90.22938	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
171_5	5	234535.974522	785139.766	9960314.612	5917.886	-0.89847	0.53641	-90.09191	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\1
202_6	6	308567.59682	787068.351	9964394.582	5935.937	-2.38056	-0.78603	-89.7001	D:\PROYECTO_ALANGASI\IMG_ZONA_E
203_6	6	308572.856286	787067.087	9963716.777	5937.976	-2.13557	0.76582	-88.91227	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
204_6	6	308578.137841	787070.447	9963038.268	5936.505	-1.79577	-0.78442	-90.79844	D:\PROYECTO_ALANGASI\IMG_ZONA_E
205_6	6	308583.418774	787070.751	9962360.173	5933.38	-2.03551	0.9667	-89.29755	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\205_6.tif
206_6	6	308588.69573	787072.733	9961680.373	5929.994	-1.59125	0.78652	-89.38266	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
207_6	6	308593.912731	787076.874	9961002.675	5924.815	-1.6786	-0.3452	-89.11369	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\207_6.tif
208_6	6	308599.091269	787078.908	9960324.481	5923.001	-1.81544	-0.88561	-89.31613	D:\PROYECTO_ALANGASI\IMG_ZONA_E
237_7	7	308960.783418	788918.58	9960450.411	5928.585	1.30869	-0.51105	90.65633	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
238_7	7	308965.728673	788919.998	9961128.77	5930.736	1.58005	-0.11507	90.80378	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
239_7	7	308970.68643	788910.004	9961806.85	5936.458	1.71069	0.65652	90.56846	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\239_7.tif
240_7	7	308975.674324	788908.788	9962486.537	5942.832	1.78639	-0.55603	90.63093	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
241_7	7	308980.668377	788905.88	9963164.251	5948.789	1.69926	-0.45804	90.65565	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
242_7	7	308985.691562	788902.606	9963843.469	5953.222	1.05743	-0.22414	90.74446	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
243_7	7	308990.705264	788899.167	9964521.28	5950.677	1.081	-0.16976	90.84248	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
276_8	8	309381.866773	790811.959	9964568.008	5981.029	-2.04404	0.87102	-89.65387	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
277_8	8	309386.584753	790817.832	9963890.318	5982.339	-2.43679	-0.20306	-89.29255	D:\PROYECTO_ALANGASI\IMG_ZONA_E
278_8	8	309391.333706	790826.314	9963210.944	6000.207	-1.10217	0.40461	-88.47429	D:\PROYECTO_ALANGASI\IMG_ZONA_ESTUDIO\2
279_8	8	309396.069675	790836.342	9962532.753	5996.498	-0.81155	-1.23499	-89.0293	D:\PROYECTO_ALANGASI\IMG_ZONA_E

Recopilación de información primaria

Control terrestre

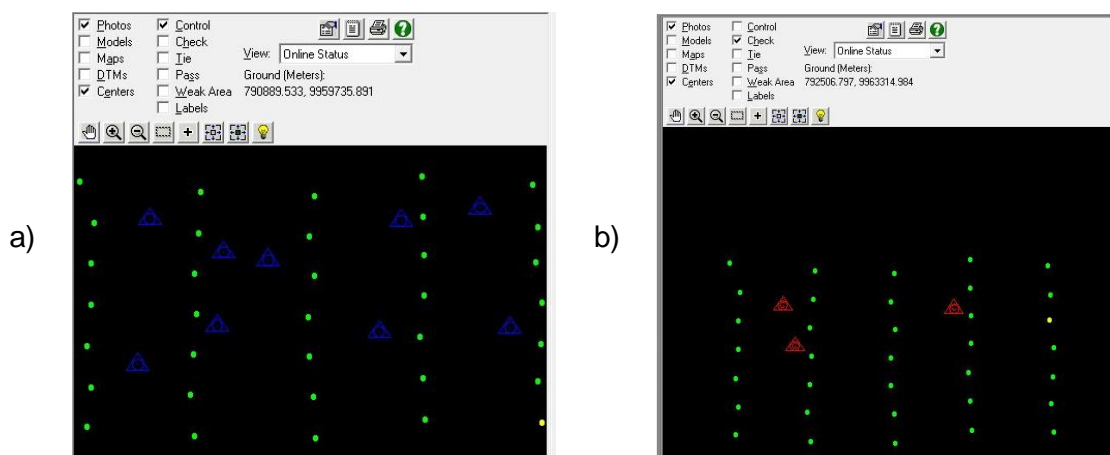
En esta fase se ejecuta la toma de puntos de apoyo fotogramétrico (GCP), check points (CP) y puntos de control de calidad (PCC). En ese sentido, se busca la mejor

distribución para los puntos que intervienen en el ajuste fotogramétrico. Los métodos de posicionamiento GNSS fueron: Estático, Estático rápido y NTRIP.

Planificación y distribución de los puntos de apoyo fotogramétrico (GCP-CP). En cuanto a la planificación, se consideraron: la distancia para posicionar el punto respecto a estaciones base más próximas, tiempo de rastreo, mejor distribución, facilidad para la toma, entre otras. Se ubican los GCP en las esquinas del proyecto, así como entre zonas de triple traslape, como se recomienda en (Chuquitarco, 2018). En la figura 26 se visualiza la distribución de los puntos de apoyo fotogramétrico (GCP) y check points (CP) dentro del bloque.

Figura 26.

Distribución de los puntos de apoyo fotogramétrico (GCP) y check points (CP)



Nota: Donde: a) distribución de GCP, b) distribución de CP.

Puntos de apoyo fotogramétrico y exactitud posicional

Puntos de apoyo fotogramétrico (Ground Control Points - GCP). Una vez obtenidas las fotografías aéreas con las que se van a trabajar, se realiza la planificación y toma de puntos de apoyo fotogramétrico (Ground Control Points GCP) con la finalidad

que sirvan como insumo para el proceso de aerotriangulación. Al respecto, se considera la toma de 9 puntos y su mejor distribución; luego, en campo se establecieron los lugares exactos en los que se ubican los GCP's. En el posicionamiento, se utiliza un receptor GNSS de doble frecuencia TRIMBLE R8, con precisión para método estático y estático rápido en horizontal de $3 \text{ mm} \pm 0.5 \text{ ppm}$ y en vertical de $5 \text{ mm} \pm 0.5 \text{ ppm}$ (Trimble, 2017). El tiempo de rastreo en el método estático es de 50 minutos en cada punto. Por otro lado, se utiliza el método NTRIP, a través del servicio proporcionado por el IGM, tomando como base la estación EPEC. En el postproceso de los puntos con el método estático se usa el software Trimble Business Center v3.5, además de la estación EPEC en ITRF08 y época de referencia 2016.4 (ubicada en la UFA-ESPE); perteneciente a la REGME (Red GNSS de Monitoreo Continuo del Ecuador). Entre los resultados, se obtienen las monografías de los GCP, alcanzando la precisión más baja en horizontal de 0.006 m y en vertical de 0.024 m.

Puntos de Chequeo (Check Points - CP). Estos puntos ayudan a evidenciar de forma independiente la calidad y precisión del ajuste fotogramétrico, a través de la comparación entre las coordenadas calculadas por el software frente a las obtenidas por métodos topográficos o geodésicos, resultado de esto se obtiene un RMS (error medio cuadrático). Los que intervienen como puntos de chequeo dentro del ajuste fotogramétrico son 3, que han sido tomados a través del método NTRIP.

Puntos de exactitud posicional. Sirven en la evaluación de la calidad de los productos obtenidos (exactitud posicional) como: modelos digitales del terreno, ortofotomosaico; así como también, de la cartografía generada por los diferentes métodos; en ese sentido, se toman 72 puntos a través del método NTRIP, considerando la misma estación y época de referencia de los puntos de apoyo fotogramétrico o de los

check points. En la figura 27 se ilustra el posicionamiento de los puntos de control terrestre.

Figura 27.

Posicionamiento del control terrestre



Evaluación de los puntos de apoyo fotogramétrico (GCP) y puntos de chequeo (CP). Luego del post proceso, se procede a la evaluación de los GCP mediante la metodología descrita en (IGM, 2006); en ese sentido, se utiliza la ecuación (9), descrita en el capítulo II. En este caso, la escala de la cartografía es 1:5000, por lo que la precisión de los GCP debe ser menor a 0.5 m.

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


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

Proceso de ajuste fotogramétrico

Luego de recopilar la información y generar los insumos, se procede a estructurar y realizar el ajuste fotogramétrico, que se encuentra detallado en el ANEXO A. El software que se utiliza en este proceso es Image Station Automatic Triangulation (ISAT), por medio de una licencia profesional propiedad del IGM, el mismo que permite la medición de puntos de paso, enlace, control y chequeo de forma tridimensional; mientras que la aerotriangulación se ejecuta por el método de haces de luz; para lo cual, utiliza las ecuaciones de colinealidad. En la figura 28, se detalla un esquema general del trabajo a ejecutar en el módulo de ISAT:

Figura 28.

Diagrama de flujo proceso de ajuste fotogramétrico



Creación del proyecto en ISAT

Se establece el nombre del proyecto, tipo de proyecto como Aerial Photography; el sistema de referencia es WGS84 UTM zona 17 Sur (para fines prácticos es igual a ITRF08). El programa requiere umbrales de aceptación del ajuste, que se detallan a continuación:

- Umbral de orientación interior: 0.6 del tamaño del píxel expresado en CCD, en base a la normativa propuesta por (IGM, 2006).
- Umbral en orientación relativa: un píxel expresado en CCD, se toma un valor ≤ 6 um, de acuerdo a la normativa de (IGM, 2006).
- Umbral para orientación absoluta: dos píxeles expresados en CCD, por lo que en el proyecto adquiere un valor ≤ 12 um, en conformidad con la normativa (IGM, 2006).
- Umbral del RMS: está determinado por la normativa (IGM, 2016) donde la precisión cartográfica es de $0.03\text{mm} \times \text{Escala de la cartografía}$; en ese sentido, el producto resultante es de escala de 1:5000, por lo que la precisión en horizontal es de 1.5 m. Este valor se encuentra dividido para tres macroprocesos (aerotriangulación, restitución, control geodésico) calculándose en 0.5 m. Dentro del proceso del ajuste fotogramétrico están inmersos los errores de geodesia y aerotriangulación, por lo que el valor se establece en 1 m.

En la figura 29, se ilustran los umbrales empleados para el ajuste fotogramétrico de este proyecto.

Figura 29.*Umbral para aerotriangulación*

User Settings

During calculations of the various orientations, certain limits need to be defined in order to determine successful or non-successful solutions. Enter the following settings and limits to be used for this project.

Acceptable IO Limits

Max Sigma: 3.6 (um)

Max Residual: 10 (um)

Acceptable RO Limits

Max Sigma: 6 (um)

Max Y-Parallax: 10 (um)

Acceptable AO/Bundle Adjustment Limits

Max Sigma: 12 (um)

	X	Y	Z	
Max RMS:	1	1	1	(m)
Max Residual:	1	1	1	(m)

< Back Next > Cancel Help

Proceso de orientación interior del ajuste

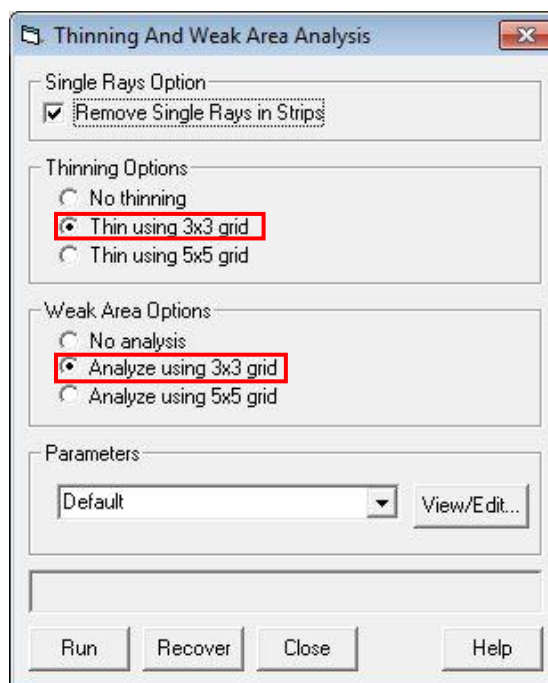
El siguiente paso, es ingresar los parámetros de la cámara junto con el insumo APPLANIX modificado (detallado anteriormente); una vez ejecutado este proceso, la orientación interior se encuentra realizada automáticamente.

Proceso de orientación relativa

En este proceso es necesario establecer los Puntos de Von Gruber; el software brinda la facilidad de generar puntos de paso y enlace de forma automática mediante correlación densa; esto se debe, a que las imágenes se encuentran orientadas de manera aproximada gracias a los centros de foto del APPLANIX. Con la ayuda de la herramienta Thinning And Weak Area Analysis, se procede a extraer los puntos de paso y enlace de manera automatizada, lo cual se observa en la figura 30.

Figura 30.


Extracción de puntos de paso y enlace de manera automática



Una vez establecidos los puntos de paso y enlace, se estudia una primera evaluación, en donde se busca que el valor de RMS, por punto, no supere los 6 μm ; en caso de que exceda, se vuelven a medir los puntos manualmente o a su vez, eliminarlos.

Proceso de orientación absoluta

El objetivo de este proceso es llevar los modelos a su verdadera posición en la tierra, para esto es necesario incluir los puntos de apoyo fotogramétrico (GCP), se ingresan y miden de forma tridimensional un total de 9 GCP's. De igual manera, con la finalidad de evaluar el ajuste, se incluyen 3 puntos de chequeo (CP). Esta información se incorpora por medio de un archivo .txt estructurado de la siguiente manera: ID, Este, Norte, Altura elipsoidal. En la figura 31 se evidencia la importación de los GCP's y CP's al proyecto de aerotriangulación.

Figura 31.**Importación de GCP y CP en ISAT****Ejecución de la aerotriangulación**

Una vez hechas las orientaciones, se concibe la aerotriangulación por el método de haces de luz. Luego, se realiza la densificación (en donde los puntos de paso y enlace se convierten en puntos aerotriangulados y adquieren coordenadas de terreno); posteriormente, se generan los modelos. Finalmente, se obtuvo un reporte de aerotriangulación, donde se evalúa el ajuste a partir de la normativa (IGM, 2006), cuyos resultados se aprecian en el apartado “Resultados del ajuste fotogramétrico”.

Evaluación del ajuste fotogramétrico


Una vez realizado el bloque fotogramétrico se evalúan los parámetros de orientación absoluta (Sigma), error residual en los puntos de control (RMS Control), error residual en los puntos de chequeo (RMS Check) y los residuales de todo el ajuste (Max. Ground Residual). Estos valores se comparan con lo propuesto por IGM (2006), en donde el sigma no sobrepasa los 12 μm ; y los RMS en los puntos, tanto de control como de chequeo, no exceden el 1 m, detallado en el apartado “Creación del proyecto en ISAT”.

Generación del MDS

La elaboración del MDS se elabora en el software INPHO de Trimble, con licencia profesional adquirida por el IGM; el empleo de este se debe a su interoperabilidad de datos; además, tiene una interfaz gráfica amigable. El procedimiento se encuentra detallado en el ANEXO B y en la figura 32 se visualiza el diagrama de flujo seguido.

Figura 32.

Generación MDS en INPHO




Se importa y convierte el proyecto de aerotriangulación generado en el software ISAT a INPHO. Luego se digitaliza un límite para extraer el MDS, posteriormente se genera la nube de puntos por correlación densa a través del módulo de MATCH-T DSM;

aquí se verifica la densidad de puntos por metro cuadrado, en este caso es de 1.03 pt/m². Al respecto, se obtienen: una nube regular de puntos y otra de forma irregular. En la figura 33 se observan los parámetros ingresados para la generación de la nube de puntos.

Figura 33.

Generación de nube de puntos

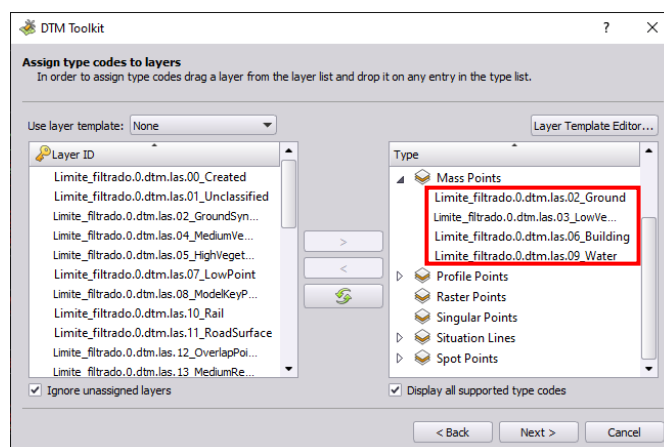


Luego de obtener la nube de puntos, a ésta se le filtra y clasifica, a través del módulo DTMaster; en ese sentido, se utilizan filtros automáticos propios del módulo. Luego se usa la herramienta Surface Modelling del módulo DTM Toolkit, que proporciona la opción de escoger las capas para generar un MDS (suelo, vegetación baja, y edificaciones) o un MDE (suelo y vegetación baja); posteriormente, en el mismo módulo, se convierten los modelos a formato TIFF. En consecuencia, se obtiene un

ráster, que se encuentra ilustrado en el apartado “Resultado del modelo digital de superficie (MDS)”. En la figura 34, se describen las capas seleccionadas.

Figura 34.

Capas para la creación del MDS



Evaluación del MDS

Con la finalidad de examinar el MDS resultante, se utilizan 24 puntos de exactitud posicional, de los que se adquiere el valor en altitud del ráster, a través de la herramienta de ArcMap 10.6 “Extract Values to Points”. Con estos datos, se calcula la diferencia entre la altura elipsoidal del punto tomado en el terreno con respecto a la extraída del MDS generado. Con los resultados obtenidos se determinan valores estadísticos como: mínimo y máximo, promedio, desviación estándar, el error cuadrático medio ($RSME_{MDE}$) y cálculo de la exactitud vertical en base a la norma NSSDA. El valor más representativo para esta evaluación es el de exactitud, aplicando la ecuación 17, tomando en cuenta que el intervalo de curva para escala 1:5000 es de 5 m.

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


$$P_V = 1.25 \text{ m}$$

Generación de las ortofotos y ortofotomosaico

En la generación de ortofotos y ortofotomosaico se utiliza el software INPHO, el procedimiento seguido se encuentra detallado en el ANEXO C. En la figura 35 se muestra un diagrama de flujo resumido del proceso.

Figura 35.

Diagrama de flujo para la generación del ortofotomosaico en INPHO




Dentro de INPHO se usa el módulo de OrthoMaster, aquí se importa el MDS generado en el apartado anterior; luego se crean las ortofotos utilizando como método

de muestreo “convolución cúbica”, formato de salida TIFF, de 8 bits. El proceso mencionado anteriormente se ilustra en la figura 36.

Figura 36.

Creación de ortofotos en el módulo de OrthoMaster



Posteriormente, mediante el módulo de OrthoVista se genera el ortofotomosaico. Las ortofotos son ingresadas; se ajusta la radiometría e intensidad; finalmente, el formato de salida es TIFF de 8 bits.

Evaluación del ortofotomosaico

Consiste en la comparación entre las coordenadas determinadas en la imagen con relación a las existentes en los puntos tomados en el terreno; en este caso, se emplean 25 puntos de exactitud posicional; así mismo, se consiguen estadísticos como: distancia mínima, máxima, media, promedio, desviación estándar, RMS, y se aplica la norma de la NSSDA relacionada con la exactitud posicional, haciendo uso de las ecuaciones 2, 3, 4, 5, 6, del capítulo II, respectivamente.

$$RMSE_x = \sqrt{\frac{2.5}{25}}$$

$$RMSE_x = 0.316 \text{ m}$$

$$RMSE_y = \sqrt{\frac{2.8}{25}}$$

$$RMSE_y = 0.334 \text{ m}$$

$$RMSE_r = \sqrt{\frac{2.5 + 2.8}{25}}$$

$$RMSE_r = 0.460 \text{ m}$$

- Caso 2: si $RMSE_x \neq RMSE_y$ se aplica la ecuación (6):

$$Exactitud r = 2.4477 \times 0.5 \times (0.316 + 0.334)$$

$$Exactitud r = 0.795 \text{ m}$$

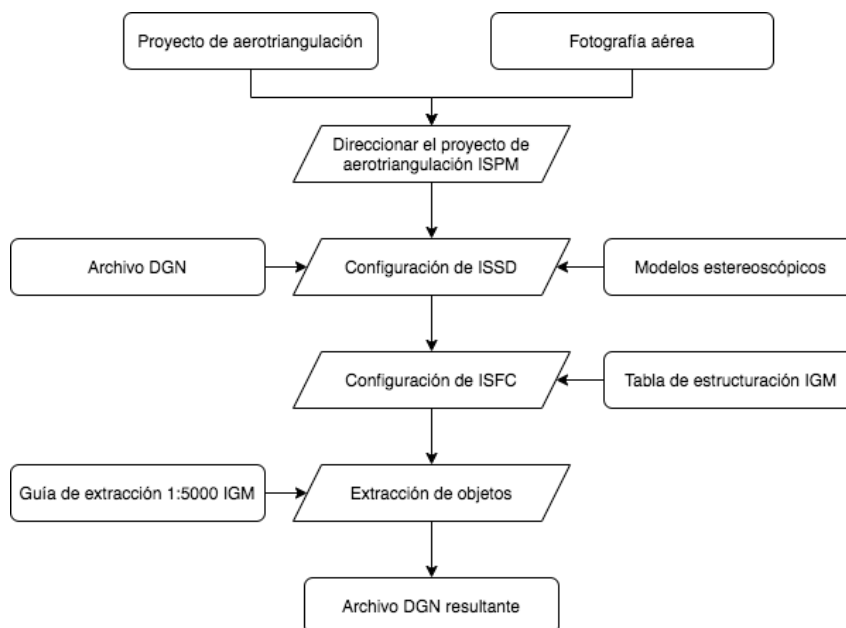
Generación de la restitución

En la realización de la restitución fotogramétrica es necesario de hardware y software específico; en ese sentido, se emplea una máquina Workstation, marca DELL, de 64 bits, con 64 Gb en RAM y tarjeta de video NVIDIA Quadro K4000; además, de un mouse fotogramétrico (softmouse) con sus debidas configuraciones. En cuanto a software, se necesitan los módulos: Image Station Photogrammetry Manager (ISPM) (en donde se direccionó el ajuste fotogramétrico), Image Station Feature Collection (necesario para la extracción de geometrías y características en 3D), Image Station

Stereo Display con licencia para MicroStation V8i (visualización y manipulación de imágenes estéreo). El proceso de restitución fotogramétrica se encuentra descrito en el ANEXO D, y en la figura 37 se visualiza el proceso seguido.

Figura 37.

Diagrama de flujo del proceso de restitución fotogramétrica

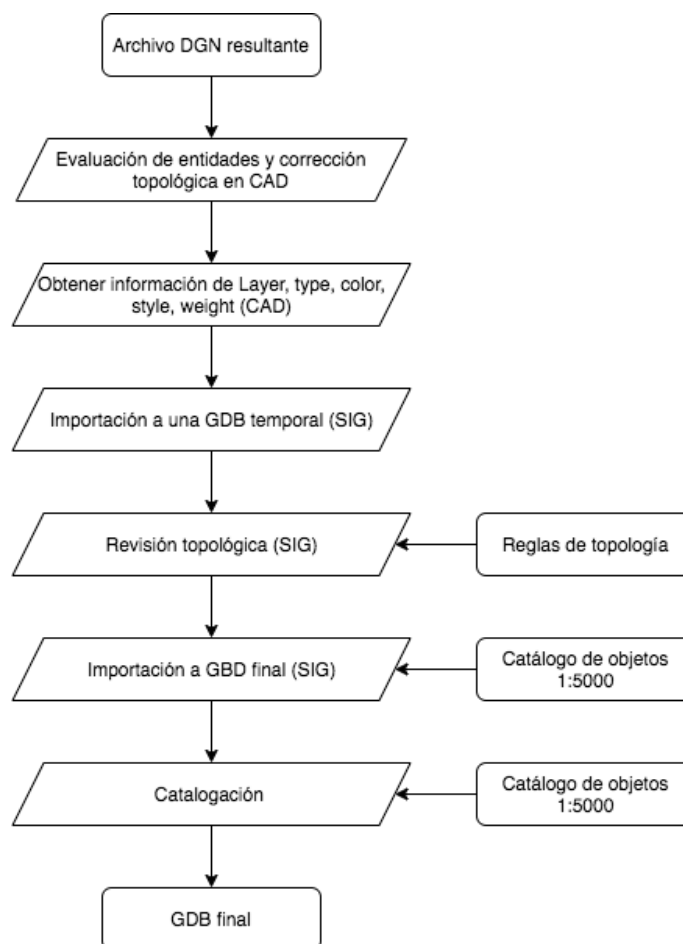


La extracción de elementos se ejecuta en base a la tabla de estructuración 1:5000 y su guía de extracción; tomando en cuenta los siguientes objetos: vías, parterre, ríos, quebradas, zona edificada, edificios. Sus resultados se indican en el capítulo IV en el apartado “Resultados de la restitución”.

CAD-SIG. Una vez finalizado el proceso de restitución fotogramétrica, se procede con la transferencia de información desde un ambiente CAD hacia un SIG, incorporando la información dentro de una geodatabase con la finalidad de estructurar topológicamente sus elementos; para esto, se utiliza el software ArcGis 10.6 a través de una licencia académica de la Universidad. El proceso se encuentra descrito en el ANEXO E y en la figura 38 se ilustra los pasos ejecutados.

Figura 38.

Diagrama de flujo del proceso CAD-SIG




Proceso de digitalización

La generación de cartografía por digitalización se desarrolla en el software ArcGis 10.6, a partir del ortofotomosaico generado anteriormente. En la extracción de objetos se utiliza el catálogo y la guía de extracción 1:5000, luego se realiza una revisión topológica; finalmente las entidades se incorporan en una base depurada. Como resultado se obtiene una GDB. En la figura 39, se evidencia un ejemplo de la extracción de cartografía por digitalización sobre ortofotomosaico.

Figura 39.

Digitalización sobre ortofotomosaico



Proceso de Deep Learning

La metodología desarrollada del proceso se encuentra descrita en el ANEXO F.

Software utilizado para Deep Learning

Con la finalidad de generar cartografía con la tecnología Deep Learning, se realiza un convenio con la empresa privada Geospace Solutions, distribuidor autorizado de L3HARRIS en el Ecuador, en donde se logra obtener licencias académicas de prueba de ENVI + IDL 5.6 incluido el módulo de Deep Learning para desarrollar este proceso.

Requerimientos de hardware para Deep Learning

Para el correcto funcionamiento del módulo de ENVI Deep Learning es necesario una computadora de alto rendimiento; en este caso, se utiliza una computadora portátil Workstation, marca DELL, con procesador Intel (R) Xeon (R) a

3.00 GHz, de 64 GB en RAM y tarjeta gráfica NVIDIA Quadro P5000 con 16 GB en GPU, sistema operativo Windows 10. En la tabla 7, se destacan los requerimientos mínimos para el funcionamiento de ENVI Deep Learning.

Tabla 7.

Requerimientos mínimos ENVI Deep Learning

Plataforma	Hardware	Versión	Tarjeta gráfica
Windows	Intel/AMD 64-bits	10, 2016 Server	NVIDIA (≥8 GB) con CUDA versión 3.5 a 7.5
Linux	Intel/AMD 64-bits	Kernel 3.10 o superior; glibc 2.17 o superior	NVIDIA (≥8 GB) con CUDA versión 3.5 a 7.5

Nota: Recuperado de (L3Harris Geospatial, 2019).

Definición de las clases (objetos a cartografiar)

Previo a la realización de la investigación se definen las clases a trabajar, entre ellas se encuentran: la extracción de vías, manzanas, parterre, ríos y edificaciones o techos; para lo cual se ejecutan entrenamientos de Deep Learning en ENVI 5.6, que nos permitan clasificar y posteriormente extraer este tipo de entidades.

Definición de ráster de entrenamiento, validación y clasificación

En primer lugar, la ortofoto se segmenta en 8 partes de igual área (200 ha), numerándolas de forma secuencial; se toman muestras de los entrenamientos y sus respectivas validaciones, exceptuando el área de estudio; la misma que sirve para la verificación de los modelos, y posteriormente la extracción de la cartografía. En la figura 40, se indica la numeración de los ráster para el entrenamiento, validación y clasificación.

Figura 40.

Ráster de entrenamiento, validación y clasificación

1	2	3
6	5	4
7	8	9

Nota: Se puede apreciar en color azul el área de estudio de extracción cartográfica, y en líneas rojas se delimitan los ráster utilizados para el entrenamiento y validación.

Extracción de las muestras

En la extracción de las muestras para el entrenamiento se utiliza la herramienta Region of Interest (ROI) del software ENVI, las mismas que se toman de forma poligonal en todas las clases (manzanas, ríos, vías, techos, parterre), debido a que las clases no son homogéneas y que se encuentran mejores resultados delimitando los elementos que componen la misma. Una vez que se extraen las muestras, estas se almacenan en archivos .xml que guardan información sobre la región de interés y la imagen a la que pertenecen. Como resultado, se obtiene una tabla con el número de píxeles y el área para todas las clases, detallada en el apartado “Resultado de extracción de muestras”. En la figura 41, se visualizan las muestras extraídas para la imagen 1.


Figura 41.

Muestras extraídas para la imagen 1



Entrenamiento de los modelos

Con la finalidad de entrenar los modelos se utiliza la herramienta “Deep Learning Guide Map” de ENVI, aquí se escogen entrenamientos multiclase debido a que en las pruebas realizadas arrojan mejores resultados que hacer con single class (clase única). Posteriormente, en la figura 42 se esquematiza el proceso a seguir para desarrollar un modelo de Deep Learning en ENVI.

Figura 42.*Diagrama de flujo para un entrenamiento Deep Learning*

Se generan ráster de etiquetas a partir de las regiones de interés (muestras), luego se ingresan los parámetros de entrenamiento descritos a continuación:

- Patch Size (tamaño del parche): es el número de píxeles a lo largo de un parche cuadrado del cual se extraen las entidades. Un número más bajo permite una mejor extracción de las clases. Un buen valor para iniciar es 484.
- Training/Validation Split (%) (entrenamiento vs validación): se refiere al porcentaje de datos que se ocupan para el entrenamiento y el restante se los utilizan para validar el modelo. Por lo general se usa 70%.
- Number of Epochs (número de épocas): establece el número de veces que el conjunto de datos pasa a través del entrenamiento, este debe ser óptimo para ajustar la ponderación. Se recomienda un valor de 25 épocas.
- Shuffle Rasters (mezclar ráster): esta opción permite mezclar los ráster de entrenamiento y validación previo a su división, esto asegura que la

información no se encuentre sesgada. Si se desactiva esta opción, el modelo utiliza las mismas imágenes tanto para entrenamiento como para validación, provocando resultados sesgados. Se sugiere activar esta opción.

- Number of Patches per Image (número de parches por imagen): el valor por defecto en ENVI es de 100. Pero a través de los entrenamientos realizados en la investigación se logran mejores resultados con valores superiores a 1000 y menores a 8000.
- Solid Distance (distancia sólida): determina el número de píxeles que rodea las entidades, en todas las direcciones, a manera de buffer, su uso es común cuando se tiene muestras de tipo puntual o lineal. Este valor no se aplica en la investigación debido a que las muestras son de tipo polígono.
- Blur Distance (distancia de desenfoco): establece la distancia mínima y máxima hasta donde se puede relacionar una entidad, más allá de la distancia sólida; esta se difumina empezando desde los bordes del área positiva hasta la distancia máxima. Este valor no se utiliza en la investigación.
- Class weight (peso de clase): proporciona el peso mínimo y máximo para tener un equilibrio uniforme de clases al momento de realizar el muestreo, el rango se encuentra entre 1 y 6. Se propone un valor de 1 a 2.
- Loss weight (peso de pérdida): se usa para sesgar la función de pérdida con la finalidad de poner más énfasis en reconocer correctamente los píxeles característicos en lugar de establecer píxeles de fondo (unclassified). Su rango se encuentra entre 0 y 3. Se aconseja un valor de 0.85.
- Output model (salida del modelo): se ingresa la dirección y nombre del modelo a entrenar, en donde se almacena el que tenga un mejor ajuste en el

entrenamiento durante todas las épocas. ENVI guarda información de los pesos y sesgos alcanzados.

- Output last model (salida del último modelo): se escoge la dirección y el nombre donde se guarda la información de los pesos y sesgos logrados en la última época. No necesariamente el último modelo es el que mejor entrenado se encuentra, pero se tiene información sobre este.

Finalmente, se tendrá el mejor y el último modelo entrenado, en la figura 43 se detallan los parámetros a ingresar:

Figura 43.

Parámetros para entrenar un modelo Deep Learning

The screenshot shows the 'Train Deep Learning Model' dialog box with the following settings:

- Patch Size: 320 (dropdown menu)
- Training/Validation Split (%): 80 (slider)
- Shuffle Rasters:
- Number of Epochs: 25 (text input)
- Number of Patches per Image: 5000 (text input)
- Solid Distance: VIAS: 0, MANZANA: 0, PARTERRE: 0 (text input)
- Blur Distance: VIAS: 0, 0, MANZANA: 0, 0, PARTERRE: 0, 0 (text input)
- Class Weight: Min 2, Max 3 (text inputs)
- Loss Weight: 0.85 (text input)
- Output Model: \\YO\manual\multiclase\entrenamiento\model_0920 (text input)
- Output Last Model: manual\multiclase\entrenamiento\last_model_0920 (text input)


Nota: Elaboración propia.

Métricas de entrenamiento

Son gráficas en tiempo real, útiles para evaluar el rendimiento de los entrenamientos, ENVI proporciona las mismas a través de la plataforma de TensorBoard (TensorFlow), en donde se toma en cuenta los gráficos de epoch_loss (pérdida por cada época) y epoch_val_loss (pérdida por época en validación). Durante la investigación se establece que estas, no son un factor determinante, para decir que un modelo esté entrenando apropiadamente; sino más bien, hacer la clasificación del ráster y visualmente establecer si el modelo clasifica de buena manera. En la figura 44, se observan las gráficas (a) epoch_loss y (b) epoch_val_loss.

Figura 44.

Gráficos de las métricas de entrenamiento




Nota: En los literales: a) se aprecia el gráfico de pérdida por época, la línea se acerca al valor 0 en sus primeras épocas, el mejor modelo ajusta sus pesos en base al menor valor mostrado en esta gráfica (en este caso la época 14). b) aquí se evidencia la pérdida por época en validación, de igual manera se reduce a 0 en sus épocas iniciales. En base a los gráficos, los valores más bajos se encuentran en la época 14, por lo que puede finalizar el entrenamiento.

Clasificar un ráster

Es asignar el valor de clase a cada píxel del ráster, con el fin de convertir a vector. Una vez entrenado cada modelo, se procede a realizar la clasificación del ráster objetivo (área de estudio, ver figura 40) a través de la herramienta “Classify Raster Using a Trained Model” de ENVI, posteriormente se obtienen: (a) un ráster clasificado, que contiene los píxeles de cada clase; y (b) el ráster de activación, en el que se almacena la probabilidad de los píxeles de pertenecer a determinada banda (clase), como se ilustra en la figura 45.

Figura 45.

Ráster de clasificación y de activación



Nota: En los apartados: a) se evidencia el ráster clasificado; en color rojo, se encuentran las vías, mientras que en color plomo se encuentran los píxeles clasificados como manzana; b) se visualiza en colores claros los píxeles que tienen una mayor probabilidad de pertenecer a la capa de vías.

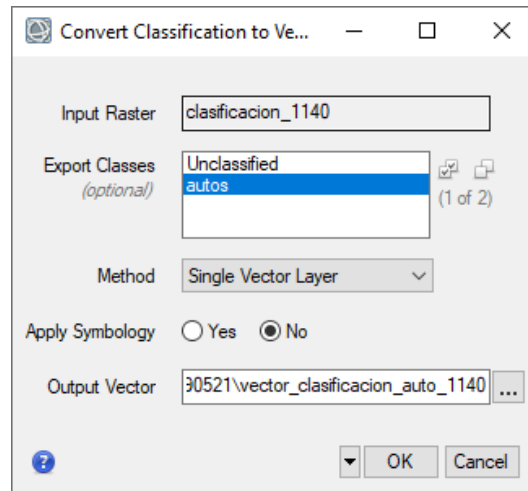
Con la finalidad de ajustar los modelos y que estos sean lo más cercanos a la realidad, se realizan iteraciones en los parámetros, hasta que los modelos concuerden lo mejor posible al momento de clasificar; para esto, se toman datos de los valores ingresados y en base a la clasificación se asignan valores (1= muy malo, 3= malo, 5= bueno, 7= muy bueno y 9= excelente). Como resultados se tiene: una tabla con la información ingresada en los entrenamientos de Deep Learning y otra con el tiempo de procesamiento detalladas en el apartado llamado “Resultados de entrenamiento de los modelos en Deep Learning”.

Elección de los mejores modelos entrenados en Deep Learning

En base a los resultados de los entrenamientos, se establecen los modelos que mejor clasifican las entidades, al no encontrar un modelo que clasifique bien todos los elementos, se optó por realizar modelos particulares (juntando distintos objetos). Las clases agrupadas son: vías, manzana, parterre (extrae vías, manzanas, y parterre); vías, techos rojos, techos azules, techos zinc (obtiene edificios); y finalmente vías, bosque, techos, ríos (recopila ríos). Como resultados se tienen los parámetros para los tres modelos, así como sus ráster, tanto de clasificación como de activación.

Exportación de ráster a vector

Por medio de la herramienta “Convert Classification to vector” se transforman los ráster clasificados en un archivo .shp para posteriormente hacer operaciones SIG. En la figura 46, se evidencia la herramienta antes mencionada de ENVI.

Figura 46.*Herramienta Convert Classification to Vector ENVI 5.6*

Como resultado se tendrá la información en formato vector, que luego se la incorpora dentro de una GDB.

Proceso de edición y generalización

Se realiza la edición y generalización de la información en formato .shp, con la finalidad de corregir errores de clasificación durante el proceso de Deep Learning; en ese sentido, se encuentran una gran cantidad de vértices producto del paso de ráster a vector, por lo que se aplica la herramienta “Simplify Line” de ArcGis 10.6. Luego se usa una serie de herramientas SIG para mejorar la parte visual como “Smooth”, “Generalize”, entre otras. Por último, se ejecuta una inspección visual de toda el área y en caso de persistir los errores, se corrigen manualmente o a su vez se completan con digitalización. En la figura 47 se muestran los errores antes mencionados.

Figura 47.

Errores de clasificación y edición de vértices



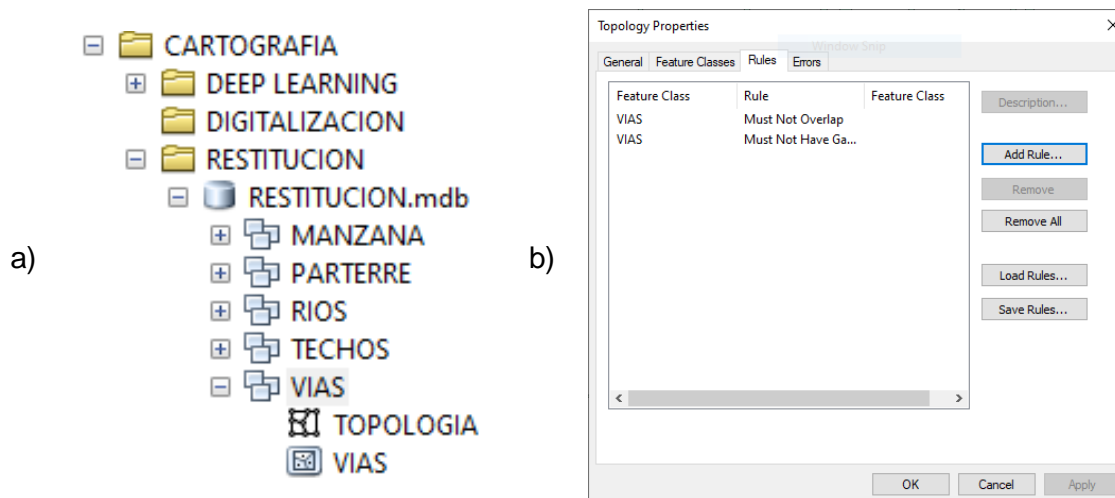
Como se visualiza en la figura 47, al momento de clasificar por la técnica de Deep Learning, los modelos no son exactos e incurren en una gran cantidad de errores, por lo que es indispensable hacer la generalización y edición de la información resultante.

Estructuración topológica

Con los vectores ya editados de las tres cartografías, se procede a incorporar dentro de una geodatabase de ESRI, con la finalidad de validar las reglas topológicas. Estas se ejecutaron en líneas (extremos sueltos, pseudo nodos) y en polígonos (no deben existir superposiciones, no deben existir saltos). Como resultado se obtienen las cartografías depuradas y listas para ser catalogadas; en la figura 48 se ilustra: a) estructura de las bases, y b) las reglas aplicadas en vías.

Figura 48.

GDB y reglas topológicas aplicadas a vías




Catalogación de las cartografías

Una vez obtenidas las GDB's depuradas de los procesos de restitución, digitalización, y Deep Learning, se continúa con la catalogación de estas. Para esto, se utiliza el catálogo de objetos 1:5000 IGM, verificando categorías, subcategorías, objetos, atributos y dentro de ellos los dominios. En la figura 49, se aprecian las entidades catalogadas.

Figura 49.

Entidades catalogadas

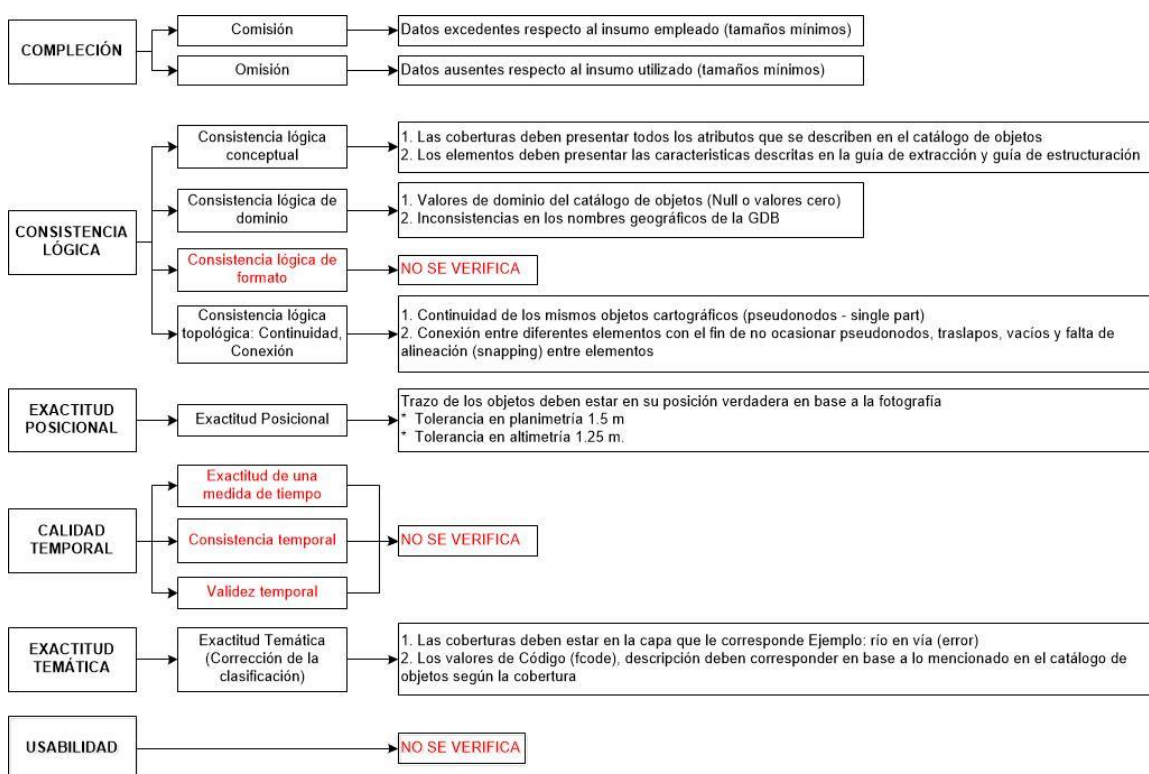


Control de calidad de datos

El control de calidad de datos geográficos se realiza en base a la norma ISO 19157, en la que se detalla la conformación y estructura de los registros en razón de medir la calidad de los datos, de las tres cartografías generadas. Aquí se determina qué elementos son aplicables para el tipo de cartografía realizada, llegando a conformar el siguiente esquema detallado en la figura 50 con el que se elabora el control de calidad de datos.

Figura 50.

Elementos aplicables de la norma ISO 19157




Control de Compleción

Se analiza datos sobrantes (comisiones) como ausentes (omisiones), para esto, se realiza una grilla de 200x200 m en la zona de estudio; en cada cuadro se verifica que

no existan omisiones o comisiones; en caso de encontrar alguna, se procede a corregir, hasta que no quede ningún error. Como resultado se tiene una tabla, que se encuentra en el apartado “Resultados de completación”. En la figura 51, se indica la distribución de cuadrícula para la verificación de omisiones y comisiones.

Figura 51.

Distribución de cuadrícula para el control de completación



Consistencia lógica

En este apartado se analiza la consistencia conceptual definida en el catálogo de objetos 1:5000; al respecto, se revisa minuciosamente que las feature class se encuentren en concordancia con lo propuesto en el mencionado catálogo. La consistencia de dominio asegura que estos, se encuentren subidos en las GDB's finales. La consistencia topológica se examina en los apartados realizados previamente antes de subirlos a la GDB depurada. Como resultado se obtiene una lista de comprobación que verifica que los campos se encuentran presentes en todos los

feature class. En la figura 52, se muestran los dominios subidos en la capa de zona edificada.

Figura 52.

Consistencia de dominio

nam	na2	adu	acc	nute	txt
		4.- Cabecera Parroquial	1.- Exact		
			<Null>		
			-1.- Informaci		
			1.- Exacta		
			2.- Aproxima		
			3.- Dudosa		
			7.- Precisa		
			998.- No aplic		

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.

nam	Nombre
na2	Nombre Turístico
acc	Código de Categoría de Precisión Horizontal
nute	Nomenclatura de las unidades territoriales estadísticas
txt	Texto Asociado

Exactitud posicional

Se materializan 32 puntos para evaluar la exactitud posicional en concordancia con la norma Positional Accuracy Standards for Digital Geospatial Data de ASPRS (mínimo 20 puntos para áreas menores a 500 km²). Estos puntos no han participado en ninguno de los procesos antes descritos (bloque fotogramétrico, evaluación de modelo digital de superficie, análisis de ortofotomosaico). Las características de estos se presentan en la tabla 8.

Tabla 8.

Características puntos de exactitud posicional

	Error horizontal [m]	Error vertical [m]	PDOP
Máximo	0.029	0.054	2.4
Promedio	0.011	0.021	1.7


Desviación estándar	0.004	0.009	0.3
Mínimo	0.006	0.008	1.2

En la tabla 8, se indica que los puntos de exactitud posicional tienen un error promedio de 1.1 cm en la componente horizontal, con una desviación estándar de 0.4 cm; mientras que en vertical el valor es de 2.1 cm, con desviación estándar de 0.9 cm. En cuanto al PDOP se evidencia que ningún punto excede el valor de 2.5.

Con estos datos se procede a extraer el valor del vértice cercano de las diferentes cartografías vs coordenadas tomadas en el terreno, luego se aplica las ecuaciones 2-8 del capítulo II, en razón de determinar el valor de exactitud posicional de la cartografía generada en base a la norma de la NSSDA. En la figura 31 se evidencia la extracción del vértice más cercano.

Figura 53.

Extracción de vértices cercanos



Como resultado de este proceso, se obtiene las tablas de exactitud posicional basados en la norma NSSDA para cada una de las cartografías, en donde se detallan los estadísticos como: distancia mínima, máxima, promedio, desviación estándar, RMSE_x, RMSE_y, RMSE_z, RMSE_r, Exactitud R (95% de confianza), Exactitud V (95% de confianza).

Evaluación de costos y tiempo de los métodos de generación cartográfica

Comparación de costos

Este proceso se realiza mediante investigación bibliográfica y entrevistas directas con los distribuidores de los productos para el Ecuador. Los precios obtenidos en este apartado tienen un carácter subjetivo, debido a que se ven influenciados por el tiempo, cantidad, país, impuestos, etc. Como resultado de este proceso se tiene una tabla comparativa desarrollada en el subtema “Resultados de comparación de costos”.

Comparación de tiempo

En esta parte se contabilizaron los tiempos que toman generar la cartografía por los diferentes métodos, basados en la experiencia vivida durante la investigación. Estos tiempos son de carácter referencial, pues depende mucho de la experiencia y conocimiento de los operadores. Como resultado se tiene una tabla comparativa de tiempos detallada en el inciso “Resultados comparación de tiempo”.

Capítulo IV

Resultados

En este capítulo se muestran y analizan los resultados obtenidos de la metodología seguida.

Resultados de la recopilación de información secundaria

Se obtuvieron los siguientes insumos: fotografía aérea, IMU/GPS (APPLANIX), licencias, información de la cámara, entre otros necesarios para el desarrollo de la investigación.

Resultados de la recopilación de fotografía aérea

En la tabla 9 se presentan los resultados de la recopilación de fotografía aérea.

Tabla 9.

Resultados recopilación de fotografía aérea

Línea de vuelo	# Foto inicial	#Foto final	Total	Fecha de toma
4	126	132	7	25 de junio de 2019
5	165	171	7	25 de junio de 2019
6	202	208	7	26 de junio de 2019
7	237	243	7	26 de junio de 2019
8	276	282	7	26 de junio de 2019

Resultado del APPLANIX

En la figura 54 se indica el APPLANIX entregado por el IGM para el desarrollo de la investigación.

Figura 54.

Archivo APPLANIX

```

25_junio: Bloc de notas
Archivo Edición Formato Ver Ayuda
*****
POS Exterior Orientation Computation Utility      Version 5.3
Copyright (C) 1997-2008 by Applanix Corporation  [Sep 24 2009]
All rights reserved.
*****

Parameter setup:
POSPROC SBET file: D:\INFORMACIÓN 2019\CESNNA CITATION\PROCESAMIENTO\25 DE JUNIO \NIII_B3c_NIII_D1a_Alangasi_NIII_E2c_NIII_E4a_Saquisili_NIV_B1c_NIV_B3a_San Jose de Poa
Camera mid-exposure event file: D:\INFORMACIÓN 2019\CESNNA CITATION\PROCESAMIENTO\25 DE JUNIO \NIII_B3c_NIII_D1a_Alangasi_NIII_E2c_NIII_E4a_Saquisili_NIV_B1c_NIV_B3a_Sa
Event time shift: 0.000000 sec
Photo ID file: D:\INFORMACIÓN 2019\CESNNA CITATION\PROCESAMIENTO\25 DE JUNIO \NIII_B3c_NIII_D1a_Alangasi_NIII_E2c_NIII_E4a_Saquisili_NIV_B1c_NIV_B3a_San Jose de Poalo\A
Photo ID file format: 3 Fields (Time, Photo ID, Delay) Format
Offset between PHOTO ID and EVENT file times: 0.000000 sec
PHOTO ID time tolerance: 0.300000 sec
WGS84 Height Output Selected
Scale the Height Output selected. Average ground height 0.990000
Mapping frame datum: WGS84 ; Mapping frame projection : TM;
central meridian = -81.000000 deg;
latitude of the grid origin = 0.000000 deg; grid scale factor = 0.999600;
false easting = 500000.000000 m; false northing = 10000000.000000 m;
Sequence of the rotation from mapping to image frame:
  First rotation is about the 'x' axis by the 'omega' angle.
  Second rotation is about the 'y' axis by the 'phi' angle.
  Third rotation is about the 'z' axis by the 'kappa' angle.
Kappa cardinal rotation: 180.000 deg.
Bore sight values: tx = -0.7680 arc min, ty = 0.0107 arc min, tz = 24.5002 arc min.
Lever arm values: lx = 0.0000 m, ly = 0.0000 m, lz = 0.0000 m.
Shift values: X = 0.000000 meter, Y = 0.000000 meter, Z = 0.000000 meter

POS/AV Computed Data at Camera Perspective Centre
Grid: Universal Transverse Mercator ;Zone: UTM South 17 (84W to 78W) ;Datum: WGS84 ;Local Transformation: NONE ;

Record Format:
ID, # EVENT, TIME (s), EASTING, NORTHING, ORTHOMETRIC HEIGHT, OMEGA, PHI, KAPPA, LAT, LONG

```

Nota: Entregado por IGM, año 2020

Resultado del APPLANIX modificado

Luego de realizar las correcciones y depuraciones necesarias, se obtiene el archivo APPLANIX modificado, que se visualiza en la tabla 10.

Tabla 10.

Archivo APPLANIX modificado

N° de Foto	L.V	Este [m]	Norte [m]	Alt. Orto. [m]	Alt. Elip. [m]	Omega [°]	Phi [°]	Kappa [°]
126	4	783322.571	9960344.081	5953.144	5979.416	1.130	0.062	91.466
127	4	783322.705	9961022.681	5952.739	5978.990	0.826	-1.050	91.546
128	4	783322.001	9961701.397	5950.129	5976.359	0.944	-0.013	91.509
129	4	783322.369	9962380.323	5949.668	5975.877	1.143	-1.151	91.809
130	4	783320.818	9963058.162	5951.766	5977.955	1.392	-1.029	92.183
131	4	783316.145	9963737.224	5954.539	5980.708	1.261	-1.961	92.495
132	4	783307.905	9964415.057	5957.879	5984.027	1.441	1.945	92.348

165	5	785118.006	9964385.443	5915.354	5941.543	-1.032	-1.565	-91.337
166	5	785117.415	9963707.500	5917.75	5943.959	-1.138	-0.962	-91.317
167	5	785116.982	9963029.121	5920.025	5946.254	-1.143	0.230	-91.137
168	5	785119.269	9962350.758	5920.503	5946.753	-1.022	-0.311	-90.974
169	5	785121.738	9961672.051	5920.771	5947.042	-1.009	0.362	-90.979
170	5	785127.466	9960994.307	5919.698	5945.989	-0.772	1.535	-90.229
171	5	785139.766	9960314.612	5917.886	5944.199	-0.898	0.536	-90.092
202	6	787068.351	9964394.582	5935.937	5962.163	-2.381	-0.786	-89.700
203	6	787067.087	9963716.777	5937.976	5964.221	-2.136	0.766	-88.912
204	6	787070.447	9963038.268	5936.505	5962.770	-1.796	-0.784	-90.798
205	6	787070.751	9962360.173	5933.38	5959.666	-2.036	0.967	-89.298
206	6	787072.733	9961680.373	5929.994	5956.300	-1.591	0.787	-89.383
207	6	787076.874	9961002.675	5924.815	5951.141	-1.679	-0.345	-89.114
208	6	787078.908	9960324.481	5923.001	5949.348	-1.815	-0.886	-89.316
237	7	788918.580	9960450.411	5928.585	5954.954	1.309	-0.511	90.656
238	7	788913.998	9961128.770	5930.736	5957.085	1.580	-0.115	90.804
239	7	788910.004	9961806.850	5936.458	5962.787	1.711	0.657	90.568
240	7	788908.788	9962486.537	5942.832	5969.141	1.786	-0.556	90.631
241	7	788905.880	9963164.251	5948.789	5975.078	1.699	-0.458	90.656
242	7	788902.606	9963843.469	5953.222	5979.491	1.057	-0.224	90.744
243	7	788899.167	9964521.280	5950.677	5976.927	1.081	-0.170	90.842
276	8	790811.959	9964568.008	5981.029	6007.299	-2.044	0.871	-89.654
277	8	790817.832	9963890.318	5992.339	6018.628	-2.437	-0.205	-89.293
278	8	790826.314	9963210.944	6000.207	6026.515	-1.102	0.405	-88.474
279	8	790836.342	9962532.753	5996.498	6022.826	-0.812	-1.235	-89.029
280	8	790842.057	9961853.901	5993.609	6019.956	-1.095	-0.877	-89.211
281	8	790845.741	9961176.304	5989.238	6015.605	-0.149	0.179	-89.035
282	8	790850.558	9960497.380	5979.135	6005.522	-0.446	-0.901	-89.101

Nota: Donde: Nº de Foto (número de foto); L.V (línea de vuelo); Alt. Orto. (altura ortométrica); Alt. Elip. (altura elipsoidal).

Resultados de recopilación de información primaria

Resultados del control terrestre

Resultado de los puntos de apoyo fotogramétrico (GCP), puntos de chequeo (CP) y monografías. En la tabla 11, se detalla el elenco de coordenadas de los puntos de apoyo fotogramétrico tomados con el equipo GNSS Trimble R8 doble frecuencia, que incluye sus precisiones.

Tabla 11.

Resultado del elenco de coordenadas Ground Control Point (GCP) y Check Points (CP)



ID	Este [m]	Norte [m]	Altura	Altura	Precisión	Precisión	PDOP	Método
			ortométrica [m]	elipsoidal [m]	horizontal [m]	vertical [m]		
GCP1	784365.569	9963862.937	2494.635	2520.824	0.003	0.005	1.7	Estático
GCP2	784163.157	9961437.388	2544.352	2570.610	0.004	0.017	1.4	Estático
GCP3	785597.702	9963312.962	2529.187	2555.417	0.005	0.009	1.4	Ntrip
GCP4	785489.503	9962089.674	2518.233	2544.742	0.007	0.012	1.4	Ntrip
GCP5	786341.890	9963180.476	2544.044	2570.292	0.004	0.009	1.7	Estático
GCP6	788194.601	9961979.183	2648.935	2675.249	0.005	0.011	1.2	Ntrip
GCP7	788544.694	9963841.377	2601.373	2627.638	0.012	0.024	1.7	Ntrip
GCP8	789868.656	9964046.095	2640.637	2666.912	0.007	0.013	1.6	Ntrip
GCP9	790345.669	9962047.240	2712.081	2738.418	0.008	0.013	1.4	Ntrip
CP1	788527.124	9963413.222	2618.871	2645.147	0.012	0.021	1.3	Ntrip
CP2	784447.613	9963481.946	2503.054	2529.256	0.006	0.011	1.6	Ntrip
CP3	784740.412	9962523.649	2521.668	2547.905	0.007	0.012	1.3	Ntrip

De acuerdo con la tabla 11, las precisiones de los puntos no sobrepasan la normativa IGM para la aceptación de GCP, que para la investigación fue de 50 cm.

En la figura 55 se observa un ejemplo de la monografía del GCP 1; el proceso se realiza para todos los GCP y CP, y estas se encuentran detalladas en el ANEXO G.

Figura 55.

Resultados de las monografías (GCP1)

UNIVERSIDAD DE LAS FUERZAS ARMADAS - ESPE		CARRERA DE INGENIERÍA GEOGRÁFICA Y DEL MEDIO AMBIENTE		ESPE	
GENERACIÓN DE CARTOGRAFÍA AUTOMATIZADA 2D A TRAVÉS DE LA TECNOLOGÍA DEEP LEARNING PARA ESCALA 1:5000, EN EL SECTOR DE CASHAPAMBA					
PROVINCIA:	CANTÓN:	PARROQUIA:			
PICHINCHA	RUMIÑAHUI	SANGOLQUI			
FECHA:	ORDEN	NOMBRE DEL PUNTO			
11-may-21	PUNTO APOYO FOTOGRAMÉTRICO	P41	GCP 1		
COORDENADAS GEOGRÁFICAS		COORDENADAS UTM:		SISTEMA DE REFERENCIA: ITRF08	
Latitud	0°19'35.81760" S	ZONA	17 S	Epoca de Referencia	2016.4
Longitud	78°26'43.04400" O	NORTE (m):	9983862.937	ITRF	2008
Altura Elipsoidal (m)	2520.824	ESTE (m):	784365.569	Elipsoide de Referencia	GRS80
Altura Ortométrica (m)	2494.635	Precisión Horizontal (m)	0.003	Precisión Vertical (m)	0.005
DESCRIPCIÓN:			Identificación del sector en la fotografía aérea		
Se llega al punto por la Av. Leopoldo Mercado, dentro de las canchas del parque Santa Clara					
MONUMENTACIÓN:			Ubicación del Punto de Control		
El punto se encuentra del ingreso al lado derecho, ubicado en la esquina de la primera cancha de basket					
ABASTECIMIENTOS:			Punto		
Se encuentra al costado izquierdo del retén policial del parque Santa Clara					
NOTA:					
* Para el cálculo de la altura ortométrica se utilizó el modelo geoidal EGM96. * El punto se encuentra ubicado en las fotografías aéreas 130_4, 131_4, 132_4					
OBSERVACIONES:					
Para la realización de este trabajo se utilizó una antena GNSS R8 Deble Frecuencia durante 60 minutos de rastreo y con un intervalo de grabación de 1 segundo.					
ELABORADO POR:		PUNTO TOMADO POR:		REVISADO POR:	
Fabricio Garcés y Edwin Argüello		Fabricio Garcés y Edwin Argüello		Ing. Eduardo Kirby	

Resultados de los puntos de exactitud posicional. En la tabla 12, se incluye el elenco de coordenadas de los puntos de exactitud posicional tomados con el GNSS Trimble R8 mediante técnica NTRIP, junto con sus precisiones.

Tabla 12.*Resultados del elenco de coordenadas de los puntos de control de calidad (PCC)*

ID	Este [m]	Norte [m]	Alt. Elip. [m]	Prec.h. [m]	Prec.v. [m]	Proceso
P1	789127,839	9964227,995	2611,021	0,007	0,014	MDS Y OTF
P2	786388,662	9963030,056	2570,114	0,011	0,021	MDS
P3	787411,358	9963940,212	2609,719	0,007	0,013	MDS Y OTF
P4	786417,381	9963210,497	2585,521	0,008	0,015	MDS
P5	785397,505	9963447,129	2554,796	0,007	0,010	MDS
P6	786830,990	9962926,952	2617,276	0,005	0,008	MDS
P7	784447,613	9963481,946	2529,256	0,006	0,011	MDS Y OTF
P8	785347,056	9962558,857	2546,708	0,011	0,017	MDS
P9	787857,333	9962817,368	2647,519	0,007	0,012	MDS
P10	785768,370	9963353,627	2564,850	0,005	0,009	MDS
P11	785594,039	9963225,559	2551,621	0,011	0,019	MDS
P12	785583,684	9963080,441	2549,632	0,012	0,020	MDS
P13	785614,477	9962730,138	2547,111	0,009	0,015	MDS Y OTF
P14	785611,131	9962699,708	2546,737	0,009	0,016	MDS
P15	785593,269	9963193,354	2551,190	0,140	0,025	MDS
P16	785438,169	9963191,383	2545,978	0,008	0,013	MDS
P17	785737,502	9962709,323	2568,049	0,007	0,012	MDS
P18	786267,966	9961924,902	2566,235	0,012	0,019	MDS Y OTF
P19	788266,250	9961356,854	2694,756	0,006	0,011	MDS Y OTF
P20	784198,538	9961727,352	2569,046	0,007	0,013	MDS Y OTF
P21	784979,881	9963093,409	2537,164	0,009	0,018	MDS
P22	785609,071	9963307,888	2555,399	0,005	0,009	MDS Y OTF
P23	785775,249	9962276,342	2551,846	0,010	0,016	MDS Y OTF
P24	788504,424	9963428,551	2647,070	0,011	0,018	MDS
P27	787408,768	9963934,209	2609,805	0,006	0,009	OTF
P28	785179,154	9962952,290	2535,283	0,013	0,022	OTF
P29	787229,094	9962668,547	2644,922	0,005	0,009	OTF
P30	786851,782	9963711,332	2568,973	0,005	0,009	OTF
P31	784947,776	9961693,063	2562,173	0,009	0,016	OTF
P32	789239,408	9961937,050	2697,217	0,011	0,017	OTF
P33	789339,664	9961516,448	2715,897	0,007	0,011	OTF
P35	789130,382	9964220,023	2611,892	0,006	0,012	OTF

P36	784740,412	9962523,649	2547,905	0,007	0,012	OTF
P38	788527,124	9963413,222	2645,147	0,012	0,021	OTF
P39	785474,949	9963181,820	2549,062	0,020	0,027	OTF
P40	785907,043	9961997,740	2555,960	0,011	0,015	OTF
P45	786186,744	9961784,310	2561,832	0,011	0,016	OTF
P46	784183,377	9961952,090	2565,154	0,007	0,012	OTF
P47	784647,939	9963624,741	2526,405	0,008	0,013	OTF
P48	785463,457	9964389,818	2550,021	0,006	0,009	OTF
P50	785439,457	9963002,818	2545,932	0,012	0,016	EXACTITUD
P51	785192,555	9962988,896	2541,989	0,013	0,020	EXACTITUD
P52	785216,506	9962730,196	2551,643	0,006	0,008	EXACTITUD
P53	785182,266	9962699,036	2547,985	0,011	0,018	EXACTITUD
P54	785175,549	9962758,456	2546,569	0,011	0,018	EXACTITUD
P55	785602,316	9962686,929	2546,065	0,010	0,016	EXACTITUD
P56	785294,806	9963252,504	2549,381	0,010	0,013	EXACTITUD
P57	785560,935	9963180,012	2550,581	0,009	0,015	EXACTITUD
P58	785597,279	9963239,434	2551,903	0,010	0,016	EXACTITUD
P59	785587,683	9963253,989	2551,908	0,009	0,015	EXACTITUD
P60	785529,017	9963245,429	2550,653	0,009	0,016	EXACTITUD
P61	785876,044	9963440,354	2574,001	0,010	0,017	EXACTITUD
P62	786538,803	9963288,085	2606,704	0,008	0,017	EXACTITUD
P63	786335,010	9963341,004	2597,019	0,029	0,054	EXACTITUD
P64	786335,109	9963223,030	2581,670	0,011	0,021	EXACTITUD
P65	785294,494	9963250,620	2549,445	0,011	0,014	EXACTITUD
P66	786432,717	9963208,123	2585,845	0,012	0,023	EXACTITUD
P67	786482,962	9963241,499	2596,435	0,016	0,029	EXACTITUD
P68	786483,089	9963234,990	2595,643	0,010	0,022	EXACTITUD
P69	786905,510	9962963,817	2629,247	0,010	0,019	EXACTITUD
P70	786595,556	9963146,592	2614,064	0,010	0,021	EXACTITUD
P71	786488,790	9962891,472	2597,552	0,006	0,013	EXACTITUD
P72	786478,809	9962853,070	2595,554	0,012	0,030	EXACTITUD
P73	787004,744	9962705,462	2637,401	0,009	0,022	EXACTITUD
P74	787005,965	9962693,969	2637,292	0,013	0,037	EXACTITUD
P75	785591,534	9963324,682	2557,856	0,007	0,016	EXACTITUD
P76	785713,117	9963529,253	2574,865	0,012	0,029	EXACTITUD
P77	785709,476	9963528,266	2574,800	0,011	0,027	EXACTITUD
P78	785392,206	9963505,011	2554,459	0,018	0,042	EXACTITUD

P79	785393,109	9963500,179	2554,457	0,011	0,028	EXACTITUD
P80	785346,609	9963371,865	2541,826	0,009	0,013	EXACTITUD
P81	785292,662	9963310,387	2543,582	0,020	0,027	EXACTITUD

Nota: Donde: Alt. Elip. (altura elipsoidal); Prec.H. (precisión horizontal); Prec.V. (precisión vertical)


La precisión horizontal mínima de los puntos de control de calidad es de 0,14 m; mientras que en vertical se tiene un valor de 0,05 m. Por otro lado, en el campo proceso se señalan 9 puntos que intervinieron tanto en la evaluación del modelo digital de superficie, así como en el ortofotomosaico.

Resultados del ajuste fotogramétrico

Los resultados luego de aplicar el módulo ISAT, mediante la distribución de 9 puntos de control y 3 puntos de chequeo, se detallan en la figura 56.

Figura 56.

Resultados del proceso de aerotriangulación ISAT




El ajuste para todo el bloque (Max Ground Residual) con 9 iteraciones, es de $RMSE_x = 0.091$ m, $RMSE_y = 0.28$ m, $RMSE_z = 0.143$ m, donde su umbral máximo es de 0.5 m; sigma de 4.6 um con el límite máximo para un ajuste absoluto de 12 um según (IGM, 2006). Otro factor preponderante al momento de evaluar un ajuste fotogramétrico, son los residuales en los puntos de chequeo; en este caso, se logran valores de $RMSE_x = 0.076$ m, $RMSE_y = 0.175$ m, $RMSE_z = 0.194$ m.

Resultado del modelo digital de superficie (MDS)

Se genera un modelo digital de superficie (MDS) de 4000 ha, a partir del ajuste fotogramétrico, cuyo resultado se aprecia en la figura 57.

Figura 57.

Resultados del modelo digital de superficie (MDS)



El MDS resultante tiene un tamaño de píxel de 1 m, cuyos valores máximos y mínimos de altura elipsoidal son 2896.02 m y de 2411.35 m, respectivamente. Se observan las elevaciones más altas en color blanco y las más bajas en celeste.

Resultados de la evaluación del modelo digital de superficie

Se obtienen estadísticas como: valor mínimo, valor máximo, promedio, desviación estándar. Además, se calcula el RMSEz y la exactitud vertical del modelo a través de la norma de la NSSDA, teniendo los siguientes resultados en la tabla 13.

Tabla 13.


Resultados estadísticos del modelo digital de superficie (MDS)

Estadísticos	Mínimo [m]	Máximo [m]	Promedio [m]	Desviación Estándar [m]	RMSEz [m]	Exactitud Vertical al 95% [m]
MDS	-0.366	0.398	0.129	0.225	0.255	0.501

El error máximo permisible en vertical para cartografía en escala 1:5000 es de 1.25 m, considerando $\frac{1}{4}$ del intervalo de curva; en base a los resultados obtenidos, se tiene que el modelo posee una exactitud vertical de 0.501 m al 95% de confianza; en consecuencia, se cumple con la normativa (IGM, 2016), y este insumo puede ser considerado para la generación de ortofotos y del ortofotomosaico. Al tomar las medidas de tendencia central, se tiene un valor promedio de 0.129 ± 0.225 m con lo que de igual manera se cumple la normativa (IGM, 2016).

Resultados de ortofotos y de Ortofotomosaico

Se obtienen un total de 35 ortofotografías; a estas, se les aplica un ajuste radiométrico y de intensidad llegando a producir el ortofotomosaico de 4000 ha que se visualiza en la figura 58.

Figura 58.*Ortofotomosaico***Resultados de la evaluación del ortofotomosaico**

Como resultado se tiene los estadísticos de: distancia máxima, distancia mínima, distancia promedio, desviación estándar, RMSE_x, RMSE_y, RMSE_r, y exactitud posicional al 95% de confianza aplicando la norma NSSDA. En la tabla 14 se aprecian los valores obtenidos.

Tabla 14.*Resultados estadísticos ortofotomosaico*

Est.	D. Min. [m]	D. Max. [m]	D. Prom. [m]	Desv. Est. [m]	RMSE _x [m]	RMSE _y [m]	RMSE _r [m]	Exactitud al 95%[m]
Ortofotomosaico	0.042	0.917	0.245	0.165	0.214	0.202	0.294	0.509

Nota: Donde: Est. (estadísticos); D. Min. (distancia mínima); D. Max. (distancia máxima); D. Prom. (distancia promedio); Desv. Est. (desviación estándar).

El error máximo permisible en horizontal para escala 1:5000 según la normativa IGM es de 1.5 m; se pudo evidenciar la exactitud posicional basados en la norma

NSSDA referente al ortofotomosaico es de 0.509 m al 95% de confianza; consecuentemente, se cumple con la normativa, y este insumo puede ser utilizado tanto para la generación de cartografía por el método de Deep Learning como por digitalización.

Resultados de la restitución

Como resultado de este proceso se tiene 200 ha de cartografía almacenadas en un archivo .dgn. En la figura 59 se puede apreciar la información generada.

Figura 59.

Resultado de restitución - Archivo .DGN




Resultado del proceso CAD-SIG

En la figura 60, se ilustra la cartografía resultante del proceso de restitución, en donde se encuentran catalogados cada uno de los objetos obtenidos, tomando en cuenta el catálogo de objetos 1:5000 propuesta por el IGM. Se obtuvieron un total de 12 feature class organizados en 6 feature dataset.

Figura 60.

Resultados de la cartografía por restitución catalogada



Resultados de la digitalización

Se digitaliza 200 ha, cuyo resultado se lo incorpora en una GDB; al igual que la base de restitución la información es catalogada. En la figura 61 se puede evidenciar las entidades resultantes de este proceso, con su respectiva catalogación.

Figura 61.

Resultados de la cartografía por digitalización catalogada



Resultados de la generación de cartografía por Deep Learning

Resultados de la extracción de muestras en Deep Learning

En la tabla 15 se indican los resultados de la extracción de muestras con el número de píxeles y el área que conforman.

Tabla 15.

Resultados de la extracción de muestras

Clases	Total de píxeles	Área [ha]
Techos rojos	1200742	4.80
Techos azules	112420	0.45
Techos zinc	2693387	10.77
Vías	32711982	130.85
Manzana	57095901	228.38
Parterre	963958	3.86
Ríos	619115	2.48
Total		381.59

Al entrenamiento se ingresan un total de 381.59 ha; de estas, la clase que mayor cantidad de muestras tiene es la de manzanas, con un total de 228.38 ha; por otro lado, la clase con menor superficie muestreada es la de techos azules, debido a su escasa presencia en el área de estudio; caso similar ocurre con la clase de ríos.

Resultados del entrenamiento de los modelos en Deep Learning

Como resultado se tienen 149 modelos entrenados, cuyos parámetros ingresados se encuentran en una base de datos incorporada en el ANEXO H; en la tabla 16 se detalla el tiempo de procesamiento alcanzado durante el entrenamiento de estos.

Tabla 16.*Resultados del tiempo de procesamiento en los modelos*

	Cantidad	Tiempo [h]	Meses	Días	Horas	Minutos	Segundos
Modelos	149	1067.31	1	14	11	18	58

En la tabla 17 se describen los parámetros ingresados en los mejores modelos obtenidos.

Tabla 17.*Parámetros ingresados en los mejores modelos obtenidos*

ID	Patch size	% Entrenamiento	Número de épocas	Parche por imagen	Class weight	Loss weight	Tiempo [h]
44	320	85	20	5000	1 A 5	0.85	24.611
65	208	85	30	1200	2A3	0.85	3.687
66*	208	70	30	1500	2 A 3	0.80	4.825
70	208	85	25	5000	2 A 3	0.85	16.525
71	208	85	25	1000	2 A 3	0.85	2.816
72	352	80	25	500	2 A 3	0.85	3.708
73**	464	85	30	1000	2 A 3	0.85	16.079
74	208	85	30	1200	2 A 3	0.85	3.618
103	208	80	25	5000	2 A 3	0.85	12.802
120	208	75	25	4000	2 A 3	0.90	13.173
133***	256	80	25	1500	2 A 3	0.60	5.690
134	272	80	30	1500	2 A 3	0.75	7.495
135	320	80	30	2000	1 A 3	0.80	15.481
141	240	95	30	2100	1 A 3	0.75	8.901
142	368	85	25	1200	1 A 4	0.70	10.242
143	720	85	25	1000	1 A 3	0.70	32.773

Nota: Donde: Patch size (tamaño del parche); % Entrenamiento (porcentaje de datos usados para entrenar vs validación); Class weight (peso de clases); Loss weight (peso de pérdida); *: mejor modelo para ríos; **: modelo utilizado para vías, manzana y parterre, ***: modelo para extracción cartográfica de edificaciones.

En base a los resultados presentes en la tabla, se puede mencionar que: los mejores modelos se dan cuando el tamaño del parche es pequeño (<484), el porcentaje

de muestras para entrenamiento vs validación supera el 70%, el número de épocas deberá ser mayor a 20, los parches por imagen son superiores a 500, el peso de clase se acomode entre 1 y 3, y el peso de la función de pérdida sea mayor a 0,7.

Resultados de elección de los mejores modelos en Deep Learning

En la tabla 18 se detallan los parámetros ingresados de los tres mejores modelos.

Tabla 18.

Resultados de parámetros ingresados en los mejores modelos


Clase	Patch size	% Entrenamiento	Número de épocas	Parche por imagen	Class weight	Loss weight
Ríos	208	70	30	1500	2 A 3	0,8
Vías, Manzana, Parterre	464	85	30	1000	2 A 3	0,85
Edificios	256	80	25	1500	2 A 3	0,6

Nota: Donde: Patch size (tamaño del parche); % Entrenamiento (porcentaje de datos usados para entrenar vs validación); Class weight (peso de clases); Loss weight (peso de pérdida).

Se seleccionan los tres mejores modelos que se ajustan a la extracción de clases particulares. En la figura 62 se visualizan los ráster de clasificación.

Figura 62.

Resultados de ráster de clasificación de los mejores modelos






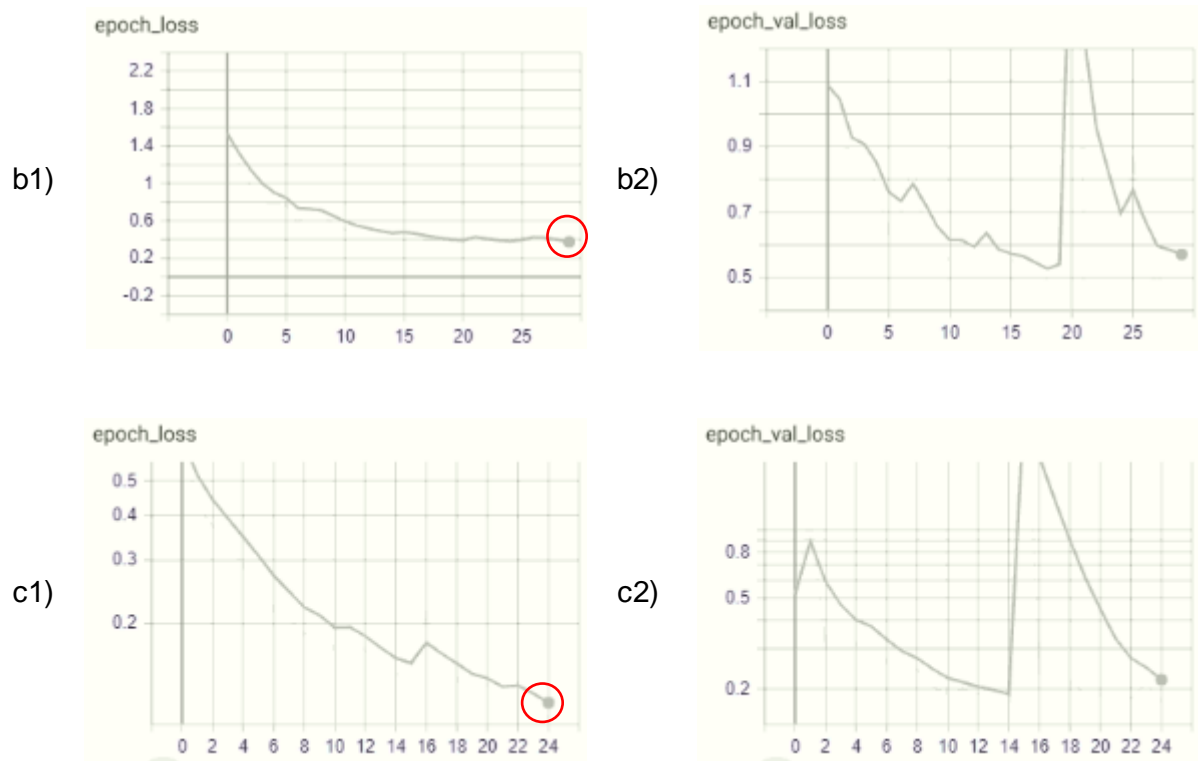
Nota: a) ráster de clasificación escogido en la extracción de la capa río_a; b) ráster de clasificación para la generación de vías, manzana y parterre; c) ráster de clasificación utilizado en la capa edificio_a.

En la investigación se determina que estos modelos son los más apropiados en la generación de cartografía y conllevan un menor tiempo en generalización, edición y topología. En la figura 63 se indican los gráficos epoch_loss (pérdida por época) y epoch_val_loss (pérdida por época en validación) para cada uno de los modelos.

Figura 63.

Resultados de las métricas de los mejores modelos escogidos





Nota: a1) gráfico de pérdida por época para la extracción de la capa rio_a; a2) gráfico de pérdida por época en validación en la capa rio_a; b1) imagen de pérdida por época en las clases vías, manzana y parterre; b2) imagen de pérdida por época en validación de las clases vías, manzana y parterre; c1) ilustración de pérdida por época en el modelo de edificaciones; c2) ilustración de pérdida por época en validación para el modelo de edificaciones. En los círculos rojos se identifican los valores más bajos en pérdida por época alcanzados en los modelos.

Como se aprecia en la figura 63, los valores de pérdida por época (epoch_loss) convergen a 0 en las primeras épocas y toman su valor más bajo en su última iteración. Por otro lado, los gráficos de pérdida por época en validación (epoch_val_loss) se muestran muy fluctuantes. Durante el procesamiento se establece que estas métricas no son un factor determinante al momento de juzgar si un modelo clasifica bien o mal,


debido a que las gráficas pueden indicar un buen ajuste, pero la clasificación no necesariamente es la mejor.


Resultados de edición y generalización

En la figura 64, en la parte a) se puede apreciar el resultado de la cartografía cruda obtenida por Deep Learning; mientras en b) se ilustra la GDB una vez editada y generalizada.

Figura 64.

Resultados del proceso de edición y generalización





En la parte a) se evidencian algunos problemas de clasificación: en color azul se identifica la clase de ríos y los errores que tiene el modelo; en color rojo se aprecian las vías, de igual manera tienen picos, ondulaciones y partes incompletas que luego del proceso se han de corregir; en polígonos rojos se detallan los techos rojos (techos de teja), mientras que los polígonos de color plomo representan techos de zinc. En la parte b) se evidencia la cartografía resultante luego de su proceso de edición y generalización.


Mediante la técnica de Deep Learning, no se pueden obtener objetos de tipo puntual (edificios con diagonal mayor a 10 m, torres de transmisión, etc.), así como de tipo lineal (sendero, cercas vías, ríos simples, líneas de transmisión, acueductos, etc.)

Resultados de la catalogación

Como resultado del proceso de catalogación, se tienen los mapas realizados con las bases finales (incluyen topología y catalogación); y se encuentran detallados en el ANEXO I. En la figura 65, se observa un ejemplo de los mapas generados con la cartografía mediante la técnica de Deep Learning.

Figura 65.

Resultado de mapa generado por la técnica Deep Learning



Resultados del control de calidad de datos

Resultados de completión

En la tabla 19 se destacan los resultados por cuadro de la verificación de omisiones (datos ausentes) y comisiones (datos excedentes) en cada una de las cartografías.

Tabla 19.

Resultados de completión

Cuadro	Omisión restitución	Comisión restitución	Omisión digitalización	Comisión digitalización	Omisión DL	Comisión DL
1	NO	NO	NO	NO	NO	NO

2	NO	NO	NO	NO	NO	NO	NO
3	NO	NO	NO	NO	NO	NO	NO
4	NO	NO	NO	NO	NO	NO	NO
5	NO	NO	NO	NO	NO	NO	NO
6	NO	NO	NO	NO	NO	NO	NO
7	NO	NO	NO	NO	NO	NO	NO
8	NO	NO	NO	NO	NO	NO	NO
9	NO	NO	NO	NO	NO	NO	NO
10	NO	NO	NO	NO	NO	NO	NO
11	NO	NO	NO	NO	NO	NO	NO
12	NO	NO	NO	NO	NO	NO	NO
13	NO	NO	NO	NO	NO	NO	NO
14	NO	NO	NO	NO	NO	NO	NO
15	NO	NO	NO	NO	NO	SI	NO
16	NO	NO	NO	NO	NO	SI	NO
17	NO	NO	NO	NO	NO	NO	NO
18	NO	NO	NO	NO	NO	NO	NO
19	NO	NO	NO	NO	NO	NO	NO
20	NO	NO	NO	NO	NO	NO	NO
21	NO	NO	NO	NO	NO	NO	NO
22	NO	NO	NO	NO	NO	NO	NO
23	NO	NO	NO	NO	NO	SI	NO
24	NO	NO	NO	NO	NO	SI	NO
25	NO	NO	NO	NO	NO	NO	NO
26	NO	NO	NO	NO	NO	SI	NO
27	NO	NO	NO	NO	NO	NO	NO
28	NO	NO	NO	NO	NO	NO	NO
29	NO	NO	NO	NO	NO	NO	NO
30	NO	NO	NO	NO	NO	NO	NO
31	NO	NO	NO	NO	NO	NO	NO
32	NO	NO	NO	NO	NO	NO	NO
33	NO	NO	NO	NO	NO	NO	NO
34	NO	NO	NO	NO	NO	NO	NO
35	NO	NO	NO	NO	NO	NO	NO
36	NO	NO	NO	NO	NO	NO	NO
37	NO	NO	NO	NO	NO	SI	NO
38	NO	NO	NO	NO	NO	NO	NO
39	NO	NO	NO	NO	NO	NO	NO
40	NO	NO	NO	NO	NO	NO	NO
41	NO	NO	NO	NO	NO	NO	NO
42	NO	NO	NO	NO	NO	NO	NO
43	NO	NO	NO	NO	NO	NO	NO
44	NO	NO	NO	NO	NO	NO	NO
45	NO	NO	NO	NO	NO	NO	NO
46	NO	NO	NO	NO	NO	NO	NO
47	NO	NO	NO	NO	NO	NO	NO
48	NO	NO	NO	NO	NO	SI	NO
49	NO	NO	NO	NO	NO	SI	NO

50 NO NO NO NO SI NO

Nota: Donde: Omisión DL (ausencia de datos en la cartografía Deep Learning);

Comisión DL (datos excedentes para cartografía Deep Learning)

Como se visualiza, tanto en digitalización como en restitución no se tuvo omisiones (datos ausentes) o comisiones (datos excedentes) en las bases finales; En la cartografía por la técnica Deep Learning a consecuencia de que no se han podido levantar objetos como rio_l o edificio_p, se tienen omisiones en los cuadros 15, 16, 23, 24, 26, 37, 48, 49 y 50. Esto no quiere decir: que no se cumple con la normativa ISO 19157, sino, más bien, que mediante esta técnica no es posible levantar la totalidad de objetos.

Resultados de consistencia lógica

En la tabla 20 se muestran los resultados de este proceso, en el que se verifica el apego al catálogo de objetos de cada una de los feature class.

Tabla 20.

Resultados de consistencia lógica

Restitución	Revisión	Digitalización	Revisión	Deep learning	Revisión
edificio_a	X	edificio_a	X	edificio_a	X
edificio_p	X	edificio_p	X	edificio_p	-
zona_edificada_a	X	zona_edificada_a	X	zona_edificada_a	-
tribuna_a	X	tribuna_a	X	tribuna_a	X
rio_a	X	rio_a	X	rio_a	X
rio_l	X	rio_l	X	rio_l	-
parterre_a	X	parterre_a	X	parterre_a	X
paseo_peat_ciclovia_a	X	paseo_peat_ciclovia_a	X	paseo_peat_ciclovia_a	X
puede_a	X	puede_a	X	puede_a	X
gasolinera_a	X	gasolinera_a	X	gasolinera_a	X
sendero_l	X	sendero_l	X	sendero_l	X
via_ruta_a	X	via_ruta_a	X	via_ruta_a	X

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

Como se observa, todas las capas tanto de restitución como de digitalización cumplen con los atributos presentes en el catálogo de objetos. En la cartografía generada por Deep Learning no se puede levantar información sobre las capas: rio_l, edificio_p y zona_edificada_a, por lo que no se encuentran dentro de la GDB.

Resultados de la exactitud posicional

En la tabla 21, se detallan los resultados de aplicar la norma NSSDA a las tres cartografías obtenidas por las diferentes técnicas.

Tabla 21.

Resultados de la exactitud posicional

	Restitución	Digitalización	Deep Learning**
Distancia mínima [m]	0.062*	0.036	0.096
Distancia máxima [m]	1.024*	0.978	1.726
Distancia promedio [m]	0.589*	0.439	0.539
Desviación estándar [m]	0.224*	0.233	0.331
RMSE _x [m]	0.257	0.352	0.379
RMSE _y [m]	0.261	0.349	0.503
RMSE _z [m]	0.511	-	-
RMSE _r [m]	0.366	0.496	0.630
Exactitud r al 95% [m]	0.634	0.858	1.079
Exactitud v al 95% [m]	1.002	-	-

Nota: *→ distancia inclinada. **→ En Deep Learning se toma en cuenta la cartografía con un proceso de edición, generalización y digitalización.

En la tabla 21, se verifica que las tres técnicas de cartografía cumplen con la exactitud requerida para escala 1:5000 en la componente horizontal (1.5 m), siendo la más exacta la generada por restitución (0.634 m), seguida por digitalización (0.858 m) y finalmente la generada por la tecnología Deep Learning (incluye edición y

generalización) (1.079 m). La principal ventaja de la restitución es su componente altimétrico, el mismo que cumple con el umbral de aceptación de (1.25 m).

Resultados de la evaluación de costos y tiempo

Resultados de comparación de costos

En la tabla 22 se muestran los resultados de la comparación de costos entre las tres cartografías generadas.

Tabla 22.

Resultados comparación de costos

	Restitución	Costo	Digitalización	Costo	Deep Learning	Costo
CPU	DELL 7910	\$ 6 181.60	LENOVO	\$1 238.00	WORKSTATION DELL	\$ 4 000.00
GPU	TARJETA NVIDIA QUADRO K4000 4GB	\$ 479.00	OPCIONAL	\$ -	TARJETA NVIDIA P500 16GB	\$ 2 877.30
MONITOR	MONITOR 3D	\$ 420.00	LG 2D	\$ 309.95	INTEGRADO EN PORTATIL	\$ -
MOUSE	SOFTMOUSE 3D	\$ 1 785.00	NORMAL	\$ 18.98	NORMAL	\$ 18.98
TECLADO	TECLADO DELL	\$ 17.50	TECLADO DELL	\$ 17.50	TECLADO DELL	\$ 17.50
SISTEMA 3D	KIT NVIDIA 3D	\$ 244.00		-		
LICENCIAS	IMAGE STATION	\$172 137.00	QGIS (Open Source)	\$ -	ENVI 5.6+ IDL + DEEP LEARNING	\$17 000.00
TOTAL		\$181 264.10		\$1 584.43		\$23 913.78

Nota: Recopilado de (Amazon, 2021; IGM, 2019).

En base a la investigación bibliográfica se puede establecer que la manera menos costosa para generar cartografía es por medio de digitalización, debido a que no se requiere de máquinas de alto rendimiento y existe la posibilidad de acceder a software libre. Una de las ventajas de la restitución, es su parte altimétrica; pero como se evidencia es una tecnología bastante costosa (licencias) con respecto a las otras dos

opciones. Por otro lado, generar cartografía por métodos de Deep Learning sería una manera alternativa viable de hacerlo, por los precios accesibles.

Resultados de la comparación de tiempo

En la tabla 23, se manifiestan los tiempos obtenidos en el desarrollo del proyecto para cada una de las cartografías generadas.

Tabla 23.

Resultados de la comparación de tiempo

Tiempo	Restitución	Digitalización	Deep Learning
Entrenamiento	0h00m00s	0h00m00s	64h00m00s*
Generación	12h00m00s	8h00m00s	1h00m00s
Generalización	0h00m00s	0h00m00s	7h00m00s
Edición	3h00m00s	1h00m00s	4h00m00s
Topología	4h00m00s	4h00m00s	4h00m00s
Catalogación	4h00m00s	4h00m00s	4h00m00s
Total	23h00m00s	17h00m00s	84h00m00s/20h00m00s

Nota: *→ tiempo para conseguir un buen modelo en Deep Learning, solo se lo considera al inicio, pues una vez que se lo tenga, se lo puede aplicar en diferentes zonas. Si no se considera este parámetro, el tiempo en generar cartografía por DL es de 20 horas.

Según los datos obtenidos, en cuanto a generación, la restitución es la que mayor tiempo toma en hacerse. Se debe considerar que para elaborar cartografía por Deep Learning el tiempo de entrenar los modelos y generar cartografía es de 84 horas. Sin considerar el entrenamiento de los modelos, el tiempo es de 20 horas para 200 ha. El único proceso en el que se aplica generalización es el de Deep Learning, esto debido a la gran cantidad de vértices existentes y errores que se presentan; el tiempo en corregirlos es alrededor de 7 horas. En todas las técnicas se ha considerado el mismo tiempo de edición, topología y catalogación (4 horas, respectivamente).

Capítulo V

Conclusiones y Recomendaciones

Conclusiones

Se cumplieron con todos los objetivos y metas considerados en el perfil, se recopiló información primaria (puntos de apoyo fotogramétrico y exactitud posicional) y secundaria (fotografía aérea, APPLANIX, certificado de calibración), los mismos que sirven como insumo para futuras investigaciones por parte de estudiantes, así como de personas externas.

Se lograron los siguientes productos: 9 puntos de apoyo fotogramétrico, 3 puntos de chequeo, 72 puntos de exactitud posicional; un ajuste fotogramétrico, modelo digital de superficie y ortofotomosaico para 4000 ha, 35 ortofotografías; cartografía por los métodos de restitución, digitalización, Deep Learning, para 200 ha; tablas de control de calidad (compleción, consistencia lógica, exactitud posicional), y tablas comparativas de costos (hardware y software) y tiempo.

Se realizó la evaluación de los productos generados, a través de las normas: (IGM, 2006, 2016), norma ISO 19157 y norma NSSDA de (FGDC, 1998) al 95% de confianza. En donde todos cumplieron los criterios establecidos por las mencionadas normas, de acuerdo a la escala 1:5000.

En cuanto a Deep Learning se evidenció una gran cantidad de errores (muchos vértices, discontinuidad de las entidades, fallos de clasificación, entre otros) por lo que el proceso de edición y generalización es indispensable, este podrá apoyarse en la digitalización con la finalidad de corregirlos. Las clases mejor clasificadas fueron: vías y techos plomos; mientras existe una deficiencia en la extracción de ríos y techos rojos.

En base a la normativa (IGM, 2006) se valoraron los puntos de apoyo fotogramétrico y el ajuste fotogramétrico, en donde se alcanza un $RMSE_x = 0.091$ m, $RMS_y = 0.280$ m, y $RMSE_z = 0.143$ m. De acuerdo con la normativa NSSDA al 95% de confianza, se tiene: modelo digital de superficie con una exactitud vertical de 0.501 m, ortofotomosaico con una exactitud posicional de 0.509 m. La cartografía por restitución detalló una exactitud posicional y vertical de 0.634 m y 1.002 m, respectivamente; la GDB de digitalización reflejó 0.858 m en exactitud posicional; en cuanto Deep Learning (incluido el proceso de edición y generalización) evidenció una exactitud de 1.079 m.

Referente al control de calidad de datos geográficos, se aplicaron los temas de: completación, consistencia lógica, de dominio, y la evaluación de exactitud posicional. En completación existieron datos ausentes en la cartografía elaborada mediante la técnica de Deep Learning, esto debido a que no se pudo levantar todos los elementos planteados. En las demás cartografías elaboradas no se tuvo mayor complicación y se cumplió con la norma.

De acuerdo con la evaluación de costos, la técnica más costosa en elaborar cartografía es la de restitución (debido al alto precio del software), superando ampliamente a los otros dos métodos, por lo que se podría probar con otros programas fotogramétricos de menor costo. Referente al tiempo, en Deep Learning se consideró el tiempo de entrenar un modelo de 64 horas, pero este se tiene únicamente al inicio; pues una vez que se tengan los modelos solo quedará utilizarlos, y el tiempo disminuirá a 20 horas. En ese sentido, no existen diferencias significativas entre los métodos de extracción cartográfica. Esta información es muy subjetiva, en razón de que es obtenida de la experiencia vivida durante la investigación.

Finalmente, es posible la generación de cartografía a través de la tecnología de Deep Learning, para escala 1:5000, los resultados obtenidos están enfocados a la zona

de estudio. También se debe considerar que no fue posible la extracción de objetos de tipo puntual (edificios con diagonal menor a 10m, monumentos, torres de comunicación), y de tipo lineal (quebradas, ríos simples, senderos, acueductos, roderas, cercas vivas).

Recomendaciones

Se recomienda realizar el ajuste fotogramétrico incluyendo más puntos de control y chequeo con la finalidad de mejorar su resultado.

Enfocar un análisis más profundo en la edición, filtrado y clasificación de la nube de puntos, esto ayudará en la generación del modelo digital de superficie, y consecuentemente el ortofotomosaico será de buena calidad.

Los resultados del proceso de Deep Learning se encuentran en función de los insumos, por lo que se puede probar con imágenes de una mayor resolución, como las obtenidas por UAV.

Se sugiere realizar una comparación con resultados obtenidos por los diferentes software que ofrecen la técnica de Deep Learning, como por ejemplo: ArcGis Pro, Matlab, R, entre otros.

La cartografía obtenida por Deep Learning está relacionada con la zona de estudio, por lo que se aconseja realizar varios análisis en diferentes zonas del país, y finalmente comparar sus resultados.

Experimentar la extracción de objetos tipo líneas y puntos por medio de Deep Learning, además de otras coberturas como por ejemplo cobertura vegetal (bosque, matorral, suelo desnudo, etc.).

Ensayar otros ámbitos de aplicación en cuanto a Deep Learning, entre ellas pueden ser la generación de cartografía de pronta respuesta en temas de: desastres naturales, agricultura, tráfico, ordenamiento territorial.

Se recomienda al IGM, realizar una actualización en sus normativas, incorporando estándares para las nuevas tecnologías utilizadas.

Bibliografía

- Almeida, M. H. B., Gomes, R. C., Almeida, O. C. P., & Ballarin, A. W. (2018).
Desempenho Da Técnica Deep Learning Na Análise E Categorização De Imagens
De Defeito De Madeira. *Energia Na Agricultura*, 33(3), 284–291.
<https://doi.org/10.17224/energagric.2018v33n3p284-291>
- Amazon. (2021). *Amazon.com: PNY NVIDIA Quadro P2200 : Electrónica*.
https://www.amazon.com/-/es/VCQP2200-SB-PNY-NVIDIA-Quadro-P2200/dp/B07VPVBLYP/ref=sr_1_3?__mk_es_US=ÅMÅŽÕÑ&crd=S7QTDFZXSE A2&dchild=1&keywords=nvidia+quadro+k4000&qid=1628652359&srefix=nvidia+quadro+k%2Caps%2C237&sr=8-3
- Angeles, G., & Gentili, J. (2010). *Cartografía General y Temática* (Universidad Nacional del Sur (ed.); 1st ed.).
- Arias, J., Villasís, A., Keever, M., Guadalupe, M., & Novales, M. (2016). Metodología de la investigación. *Alergia México*, 63, 201–206. www.nietoeditores.com.mx
- Arias, M. (2013). *El significado de los intervalos de confianza*. XV, 91–94.
- ASPRS. (2009). Guidelines for procurement of professional aerial imagery, photogrammetry, lidar and related remote sensor-based geospatial mapping services. *Photogrammetric Engineering and Remote Sensing*, 75(12), 1346–1365.
http://www.asprs.org/wp-content/uploads/2010/12/ProcurementGuidelines_SubmittalforBoardApproval_081409.pdf
- Barragán, G. (2015). *Generación de ortofotos y cartografía 2D y 3D mediante procesos fotogramétricos digitales con Intergraph Erdas Imagine*. Universidad de las Fuerzas Armadas - ESPE.

- Berné, J., Garrido, N., & Capilla, R. (2019). *GNSS: GPS, GALILEO, GLONASS, BEIDOU: Fundamentos y métodos de posicionamiento* (Univesitat Politècnica de València (ed.)). [https://riunet.upv.es/bitstream/handle/10251/70627/TOC-Berné%3BAquel%3BGarrido - GNSS. GPS FUNDAMENTOS Y APLICACIONES EN GEOMÁTICA.pdf?sequence=4&isAllowed=y](https://riunet.upv.es/bitstream/handle/10251/70627/TOC-Berné%3BAquel%3BGarrido%3BGNSS.GPS.FUNDAMENTOS.Y.APLICACIONES.EN.GEOMÁTICA.pdf?sequence=4&isAllowed=y)
- Briceño, A., Mass, L., Rubí, Cioce, V., Royero, G., Bacaicoa, L., Wildermann, E., Hoyer, M., & Barrios, M. (2009). Mediciones GPS NTRIP: Una nueva alternativa para el posicionamiento preciso en Venezuela. *Revista Técnica de La Facultad de Ingeniería Universidad Del Zulia*, 32(3). <http://ve.scielo.org/pdf/rffiuz/v32n3/art03.pdf>
- Buitrón, S. (2009). *Estudio del efecto ionosférico en la falsa distancia con señales GPS y GLONASS* [Univerisidad de las Fuerzas Armadas - ESPE]. <http://repositorio.espe.edu.ec/bitstream/21000/903/1/T-ESPE-026608.pdf>
- Caimel Benítez, J. (2002). *Ortorrectificación De Fotografías Aéreas Utilizando El Software Erdas Imagine*. <http://www.cartografia.cl/download/manuales/erdas.pdf>
- Chang, K. (2019). Introduction to Geographic Information Systems. In McGrawHill (Ed.), *Libraries* (9na ed.). <https://doi.org/10.1201/b12440-10>
- Chicaiza, E. (2017). *ISO 19157 : Calidad de datos y su relación con las normas de la familia ISO 19100*. https://www.ide.cl/descargas/SEMINARIO_NIG/PRESENTACIONES/4EG.pdf
- Chuquitarco, A. (2018). *Análisis de los métodos de aerotriangulación y número de puntos de control sobre la calidad de las ortofotos con ERDAS LPS CORE y ORIMA* [Universidad de las Fuerzas Armadas - ESPE]. <https://repositorio.espe.edu.ec/bitstream/21000/15030/1/T-ESPE-040400.pdf>
- Claros Z., R. A., Guevara A., A. E., & Pacas C., N. R. (2016). *Aplicación de*

Fotogrametría aérea en levantamientos topográficos mediante el uso de vehículos aéreos no tripulados [Universidad de El Salvador].

<http://ri.ues.edu.sv/id/eprint/14218/1/50108282.pdf>

Conde Ortiz, D. (2018). *Inteligencia artificial con TensorFlow para predicción de comportamientos* [Universidad de Sevilla].

https://idus.us.es/handle/11441/80122#.X0neHv_vQyY.mendeley

De la Fuente, V. (2019). *Diseño evolutivo de arquitecturas de Deep Learning para detección de vías de transporte* . 120.

Diaz de Leon, N. (2015). Técnicas de Investigación Cualitativas y Cualitativas FAD UAEMex. *Universidad Autónoma Del Estado de México*, 1–134.

DronDeploy. (2019). *What are ground control points?*

<https://www.dronedeploy.com/blog/what-are-ground-control-points-gcps/>

ESRI. (2016). *Una vista general de las herramientas de Generalización*.

<https://desktop.arcgis.com/es/arcmap/10.3/tools/cartography-toolbox/an-overview-of-the-generalization-toolset.htm>

ESRI. (2021). *Introduction to ortho mapping—ArcGIS Pro | Documentation*.

<https://pro.arcgis.com/en/pro-app/latest/help/data/imagery/introduction-to-ortho-mapping.htm>

Felicísimo, A. (1994). Modelos digitales del terreno: introducción y aplicaciones a las ciencias ambientales. In Universidad de Extremadura (Ed.), *Oviedo: Universidad de Oviedo*. <http://www6.uniovi.es/~feli/pdf/libromdt.pdf>

FGDC. (1998). Geospatial Positioning Accuracy Standards Part 3 : National Standard for Spatial Data Accuracy. *National Spatial Data Infrastructure*, 28.

<http://www.fgdc.gov/standards/projects/FGDC-standards-projects/accuracy/part3/chapter3>

GADMUR. (2019). *Plan de Desarrollo y Ordenamiento territorial Cantòn Rumiñahui 2012-2025*.

[http://181.112.151.212/Documentacion/RENDICION_DE_CUENTAS/2017/PDYOT_2014 - 2019 FINAL.pdf](http://181.112.151.212/Documentacion/RENDICION_DE_CUENTAS/2017/PDYOT_2014_-_2019_FINAL.pdf)

García Flores, P., & Ortiz de Elguea, E. (2012). *Influencia del GSD en la orientación de un bloque fotogramétrico* (Universidad del País Vasco (ed.)).

García, S. (2017). *Ciencia, Tecnología y sociedad: entorno global en el desarrollo del GPS* [Universidad Politécnica de Madrid].

http://oa.upm.es/49357/1/PFC_SUSANA_ALICIA_GARCIA_BAHON.pdf

GeospaceSolutions. (2019). *Envi software avanzado en ciencia de imágenes*.

<https://www.geospace-solutions.com/envi>

Ley De Cartografía Nacional, (1978).

https://www.gob.ec/sites/default/files/regulations/2018-10/Docuemento_Ley-Cartografía-Nacional.pdf

Gómez, M. del P. (2016). Aprendizaje profundo: El poder del aprendizaje automático unido al poder de cálculo de las computadores actuales. *Investigación y Ciencia (Scientific American)*, AGOSTO(479), 37.

<http://ccc.inaoep.mx/~pgomez/conferences/PggTSys16.pdf>

González, P. (2015). *Levantamiento Mediante Gps de una red de puntos establecidos para correlacionar los distintos espacios de la universidad en el mismo sistema de coordenadas* [Universidad Politécnica de Cartagena].

<https://repositorio.upct.es/bitstream/handle/10317/4651/pfc5890.pdf>

- Guamán, S. (2020). *Procesamiento y restitución de imágenes capturadas por drone multirrotor a través de photomod uas en el sector de Alangasí*. Universidad de las Fuerzas Armadas - ESPE.
- Guinea, A. (2014). *Calidad de geo - procesos vs calidad de geo - datos*.
https://www.ideo.es/resources/presentaciones/JIIDE14/20141107/Calidad-geoinformación_presentacion.pdf
- Hexagon. (2021). *ImageStation 2020* (Hexagon (ed.)).
https://bynder.hexagon.com/m/32b9c80b09a89cde/original/Hexagon_GSP_ImageStation_Product_Description.pdf
- Ibáñez, E. (2008). *Validación De Modelos Digitales Del Terreno De Precisión a Partir De Datos Láser Escáner Aerotransportado; Aplicación a la Marisma Del Parque Nacional De Doñana*. Universidad Politécnica de Cataluña.
- Ibérica. (2018). *Comprobación del resultado de la aerotriangulación con Match - AT*. 1–11.
- IDECA. (2015). *Cómo evaluar y reportar la calidad de los datos espaciales*.
<https://www.ideca.gov.co/sites/default/files/presentaciones/idecacursotallerestandar ycalidad.pdf>
- IDECA. (2019). *Procedimiento para la evaluación y reporte de calidad de datos geográficos*. (IDECA (ed.)).
<https://www.ideca.gov.co/sites/default/files/Procedimientoevaluacionyreportecalidad dedatosgeograficos.pdf>
- IGAC. (2016). *Especificaciones técnicas Cartografía Básica Digital* (I. G. A. Codazzi (ed.)).

- IGM. (2006). *Especificaciones Técnicas Generales Para La Realización De Cartografía Topográfica a Cualquier Escala (Primer Borrador)*. 1–29.
<http://www.geoportaligm.gob.ec/portal/>
- IGM. (2013). Metodología Utilizada Para La Generación De Cartografía Básica Del Ecuador Territorial Escala 1 : 500**. In *Tenth United Nations Regional Cartographic Conference for the Americas* (Instituto).
- IGM. (2016). *Especificaciones Técnicas para la producción de Cartografía Escala 1:5000*. 1–37. http://www.geoportaligm.gob.ec/portal/?wpfb_dl=851
- IGM. (2018). *Protocolo de fiscalización para proyectos de generación de cartografía base con fines catastrales escala 1:1 000, obtenida a través de método aerofotogramétrico, digitalización 2D sobre ortofoto o levantamiento topográfico*. (IGM (ed.)).
- IGM. (2019). *Obtención de cartografía básica oficial actualizada del país multiescala* (p. 220).
- Instituto Geográfico Nacional. (2010). *Fotogrametría y Teledetección*. Upc, 566.
<http://www.ign.es/web/resources/docs/IGNCnig/QSM-CNIG-Becas-Temario-A2.pdf>
- Instituto Geográfico Nacional. (2014). *Unidad 4: Herramientas avanzadas*. *Generalización cartográfica* (IGN (ed.)).
- Jarandilla, V. (2014). *Restitucion Fotogrametrica Digital Para La Generación De Un Mapa Fisiográfico Y Uso Actual De La Tierra Distrito Puerto Carabuco - Municipio De Puerto Mayor Carabuco - Prov. Camacho - Depto. La Paz* [Universidad Mayor de San Andrés]. [http://repositorio.umsa.bo/bitstream/handle/123456789/9578/PG-1358-Jarandilla Altuzarra%20 Vladimir.pdf?sequence=1&isAllowed=y](http://repositorio.umsa.bo/bitstream/handle/123456789/9578/PG-1358-Jarandilla%20Altuzarra%20Vladimir.pdf?sequence=1&isAllowed=y)

- Jauregui, L. (2012). *Fotogrametría Básica* (U. de los Andes (ed.)).
<http://webdelprofesor.ula.ve/ingenieria/iluis/>
- L3Harris Geospatial. (2019). *Envi Deep Learning Module*. 25–26.
https://www.l3harrisgeospatial.com/Portals/0/pdfs/HarrisGS_DeepLearning_Datash eet_LoRes.pdf
- L3Harris Geospatial. (2020a). *Training Background*.
<https://www.l3harrisgeospatial.com/docs/backgroundtraindeeplearningmodels.html# Epochs>
- L3Harris Geospatial. (2020b). *Training metrics*.
<https://www.l3harrisgeospatial.com/docs/ViewTrainingMetrics.html>
- Lepage Chumpitaz, C. (2016). Aplicaciones actuales de la inteligencia artificial y su uso con la tecnología IBM Watson. *Repositorio de Tesis - UNMSM*, 0, 54.
<http://200.62.146.31/handle/cybertesis/7030>
- Lerma, J. (2002). *Fotogrametría Moderna: Analítica y Digital* (Universidad Politécnica de Valencia (ed.)).
- Lind, D. A., Marchal, W. G., Wathen, S. A., Iván, J., Sánchez -Farley, J., Rojas, S., Julieth, R.-H., Galvis, O., Iván Jiménez Sánchez, J., Sary, F., Restrepo, R., Julieth, H., Scherger, V. P., Arbelaez R, M. A., Zulet J, L. A., Velazco M, A., Rosales R, M. F., Dominguez G, C., Economicas, D. E. C., ... Analisis, E. N. E. L. (2012). Estadística aplicada a los Negocios y la Economía. In M. Hill (Ed.), *Ciencia y Sociedad: Vol. XVI* (15ta Edici, Issue 4).
<https://cape.fcfm.buap.mx/jdzf/cursos/est1/libros/book1e1.pdf>
- López, P. L. (2004). Población muestra y muestreo. *Punto Cero*, 9(31), 35–54.
http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S1815-

02762015000200005&lng=es&nrm=iso

López, S., & Martín, S. (2016). *Métodos y productos cartográficos* (Síntesis (ed.)).

<https://www.sintesis.com/data/indices/9788490774793.pdf>

Luna, J. (2009). *Fotogrametría Digital I*.

http://www.ptolomeo.unam.mx:8080/jspui/bitstream/132.248.52.100/16280/1/decd_5220.pdf

Management Solutions. (2018). Machine Learning, una pieza clave en la transformación de los modelos de negocio. In Management Solutions (Ed.), *Management Solutions*.

<https://www.managementsolutions.com/sites/default/files/publicaciones/esp/machine-learning.pdf>

Matich, D. J. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. *Historia*, 55.

<ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>

Mayorga, O. A., & Andaluz, V. H. (2018). Autonomous control through the level of

fatigue applied to the control of autonomous vehicles. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture*

Notes in Bioinformatics), 11357 LNAI, 115–126. https://doi.org/10.1007/978-3-030-05204-1_12

Millán, J. (2006). *Fundamentos para Cartografía Náutica* (J. M. M. Gamboa (ed.)).

Miranda, P. M., Arizmendi, F. R., & Valadez, A. S. (2006). Conceptos básicos de estadística descriptiva útiles para el médico. *Artemisa*, 7(1), 42–46.

Mora, M. F. (2016). *Fundamentos De Deep Learning Y Una Aplicacion Para Predecir La Demanda De Energia Electrica En Mexico* [Instituto Tecnológico Autónomo de

- México]. https://sophie-germain.github.io/deeplearning_thesis.pdf
- Moreno, M., & Ramírez, D. C. (2018). *El uso de la fotogrametría para la digitalización de documentos cartográficos de gran formato: la experiencia de la Planoteca de la Junta de Adelanto de Arica (PJAA), Chile*. 17, 80–90.
- Nacelle, A. (2009). *Redes Neuronales Artificiales* [Universidad de la República].
[https://doi.org/10.1016/S0210-5691\(05\)74198-X](https://doi.org/10.1016/S0210-5691(05)74198-X)
- Olaya, V. (2014). *Sistemas de Información Geográfica* (V. Olaya (ed.)).
<http://marefateadyan.nashriyat.ir/node/150>
- Orellana, R. (2006). *Apuntes de fotogrametría*. o
- Peñafiel, J., & Zayas, J. (2001). *Fundamentos del sistema gps y aplicaciones en la topografía* (Colegio Oficial de Ingenieros Tecnicos en Topografía (ed.)).
<http://www.rutasnavarra.com/gps/teoria/gpsavanzado.pdf>
- Pérez, B. (2018, March). Inteligencia Artificial. *INCyTU*, 12.
<https://doi.org/10.4114/ia.v2i6.614>
- Pérez, G. (2012). *Anexo 6 Breves apuntes sobre la teoría de errores*. 100, 903–917.
- Quirós, E. (2014). *Introducción a la Fotogrametría y Cartografía aplicadas a la Ingeniería Civil* (Universidad de Extremadura (ed.)).
<https://core.ac.uk/download/pdf/72045983.pdf>
- Ramiro, A., & Alvarado, V. (2020). *Machine Learning para Todos Aldo Valdez Alvarado*. January 2019. <https://doi.org/10.13140/RG.2.2.13786.70086>
- Redgeomática. (2018). *CAPITULO I: Introducción al DISEÑO CARTOGRAFICO*.
http://redgeomatica.rediris.es/cart02/arb01B/cart0B/Bcap1/1_6.htm
- Reuter, F. (2002). Práctica 4. Paralaje estereoscópica. In Universidad Nacional de

- Santiago del Estero (Ed.), *Carpeta de Trabajos Prácticos: Teledetección Forestal* (a, pp. 23–29). <https://fcf.unse.edu.ar/archivos/lpr/pdf/p4.PDF>
- Ríos, A., & Puerto, L. (2019). *Control terrestre en el proceso fotogramétrico usando vehículos aéreos no tripulados con fines cartográficos en el municipio de Cóbita* (Universidad Distrital Francisco José de Caldas (ed.)).
<https://repository.udistrital.edu.co/bitstream/handle/11349/15113/PuertoCaroLauraNatalia2019.pdf?sequence=2>
- Sánchez, J. (2007). *Introducción a la Fotogrametría*.
- Santamaría, J., & Sanz, T. (2011). *Fundamentos de fotogrametría* (U. de la Rioja (ed.)).
- Santos, L. (2007). *Digitalización mediante escaneo masivo del archivo de ortofotos de la Dirección General del Catastro*. 51–74.
http://www.catastro.meh.es/documentos/publicaciones/ct/ct59/51_74.pdf
- Sarría, F. (2015). *Sistemas de Información Geográfica* (Universidad de Murcia (ed.)).
<https://www.um.es/geograf/sigmur/sigpdf/temario.pdf>
- Solovey, D. (2017). *Classificação de terreno em fotografia aérea de grande resolução com recurso a Deep Learning*. Instituto Técnico de Lisboa.
- Spolti, A. C. (2018). *Classificação de vias através de imagens aéreas usando Deep Learning*. 31.
- TensorFlow. (2018). *TensorBoard: el kit de herramientas de visualización de TensorFlow*. <https://www.tensorflow.org/tensorboard>
- Trimble. (2017). *Sistema Trimble R8 GNSS*.
<https://cn.geospatial.trimble.com/sites/geospatial.trimble.com/files/2019-03/Datasheet - Trimble R8s GNSS System - Spanish - Screen.pdf>

Valdés, L., & Baquero, J. (2019). *Deep Learning aplicado a imágenes satelitales como herramienta de detección de Viviendas Sin Servicio de energía en el caserío Media Luna-Uribia-Guajira*. Univerisdad Distrital Francisco José de Caldas.

Xakata. (2020, February 24). *Otro clavo más en el ataúd de la tecnología 3D: Nvidia dejará en breve de ofrecer soporte para el sistema 3D Vision*.

<https://www.xatakahome.com/televisores/otro-clavo-ataud-3d-nvidia-dejara-breve-ofrecer-soporte-para-sistema-3d-vision>