

Universidad Pública de Navarra

**ESCUELA TECNICA SUPERIOR
DE INGENIEROS AGRONOMOS**

Nafarroako Unibertsitate Publikoa

*NEKAZARITZAKO INGENIARIEN
GOI MAILAKO ESKOLA TEKNIKO*

**PROPUESTA METODOLÓGICA DE EVALUACIÓN DE CLASIFICACIONES
LIDAR: ESTUDIO DE CASO SOBRE DATOS DEL PLAN DE ORTOFOTOGRAFÍA
AÉREA (PNOA)**

presentado por

SAIOA GARCÍA RODRÍGUEZ *(e)k*

aurkeztua

**MÁSTER EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y TELEDETECCIÓN
*MASTERRA INFORMAZIO SISTEMA GEOGRAFIKOETAN ETA TELEDETEKZIOAN***

Septiembre del 2019 / *2019ko iraila*

Resumen

La clasificación es uno de los procesos más importantes para poder generar productos cartográficos a partir de datos LiDAR. Aunque en la actualidad existen diversos algoritmos de clasificación y se sigue trabajando intensamente en este campo, la forma de evaluar los resultados de las clasificaciones ha evolucionado poco, utilizándose en general métricas estándar. Esto puede ser problemático ya que estas métricas tratan por igual errores de distinta gravedad que pueden tener un impacto muy distinto en los productos derivados. El objetivo de este trabajo es generar una herramienta de validación que evalúe la clasificación de las nubes de puntos teniendo en cuenta la gravedad de cada error. La metodología propuesta se ha implementado en un estudio de caso en el que se evalúan distintos modelos de clasificación obtenidos a partir de muestras de diferentes sensores y densidades disponibles en el Plan de Ortofotografía Aérea (PNOA). Como conclusión, se puede afirmar que la herramienta de validación propuesta proporciona varias métricas que reemplazan la necesidad de una inspección visual y se agregan a las métricas de evaluación estándar.

Palabras clave: LiDAR, validación, minería de datos, clasificación supervisada

Abstract

Classification is one of the most important phases to generate any cartographic product from LiDAR data. Although there are currently several classification algorithms and there is still intense work in this field, the procedure to evaluate the results of classifications has not evolved much, being mostly based on standard metrics. This can be problematic since these metrics treat errors of varying severity equally, which can have a very different impact on products. The aim of this research is to generate a validation tool that evaluates the classification of point clouds taking into account the severity of each error. A case study was carried out implementing the proposed method on different classification models obtained with a range of different datasets. In conclusion, the validation tool provides several metrics that supersede the necessity of a visual inspection and add to the standard evaluation metrics.

Keywords: LiDAR, validation, data mining, supervised classification

Laburpena

Datuen klasifikazioa LiDAR teknologiarengandik lortutako produktu kartografikoak sortzeko prozesu garrantzitsuenetako bat da. Gaur egun, sailkapen algoritmo ugari eta arlo horretan lan handia dagoen arren, sailkapenen emaitzak ebaluatzeko moduak gutxi eboluzionatu dute, orokorrean neurri estandarrak erabiliz. Hau arriskutsua izan daiteke, neurri horiek akats guztiak berdín tratatzen dituzte eta. Lan honen helburua puntu lainoen sailkapena ebaluatzen duen balioztatze tresna bat sortzea da, akats bakoitzaren larritasuna kontuan hartzen duena. Proposatutako metodologia kasu azterketa batean ezarri da, non *Plan de Ortofotografía Aérea*-n (PNOA) eskuragarri dauden sentso-re eta dentsitate desberdinetako datuetatik sailkapen eredu desberdinak sortu eta aztertu dira. Konklusio bezala, esan daiteke proposatutako balioztatze tresna ikuste-ikuskapenaren beharra ordezkatzeko duten hainbat metrika ematen dituela, ebaluazio estandarreko neurri gehituz.

Hitz-gakoak: LiDAR, balioztatze, datu meatzaritza, gainbegiratutako klasifikazioa

Agradecimientos

Agradezco a la empresa Tracasa y a todo su equipo por el tiempo y esfuerzo dedicado para la realización de este trabajo, en especial a Víctor García por su ayuda y colaboración en todo momento.

También quería agradecer el apoyo de los profesores Jesús Álvarez y Mikel Galar por haber sido mi guía durante la redacción de mi Trabajo de Fin de Máster.

ÍNDICE

Resumen.....	i
Abstract.....	ii
Laburpena.....	ii
Agradecimientos.....	iii
1. Introducción.....	1
1.1. Preámbulo.....	1
1.2. Antecedentes.....	2
1.2.1. Tecnología LiDAR.....	2
1.2.2. Estado del arte.....	7
1.3. Objetivos.....	10
2. MATERIALES Y MÉTODOS.....	11
2.1. Introducción.....	11
2.2. Base del trabajo.....	11
2.2.1. Proyecto PNOA.....	11
2.2.2. Segunda cobertura de Navarra: Vuelo y clasificación.....	14
2.3. Aportaciones metodológicas.....	22
2.3.1. Fase I: Validador.....	22
2.3.2. Fase II: Clasificación.....	35
3. RESULTADOS.....	45
3.1. Validación del bloque con los modelos generados.....	45
3.1.1. Resultados obtenidos en las áreas de entrenamiento.....	45
3.1.2. Validación de los datos de ALS80 a 0,5 p/m ² sobre el bloque de referencia...46	46
3.1.3. Validación de los datos de Riegl Q-680 a 0,5 p/m ² sobre el bloque de referencia 49	49
3.2. Validación del bloque con el modelo generalista de clasificación.....	52
3.2.1. Resultados obtenidos en las áreas de entrenamiento.....	52
3.2.2. Validación sobre el bloque de referencia.....	53
3.3. Análisis de los resultados.....	56
4. CONCLUSIONES.....	58
4.1. Conclusiones generales.....	58
4.1.1. Validación.....	58
4.1.2. Clasificación.....	58
4.2. Aportaciones del trabajo y futuras líneas de investigación.....	59
5. REFERENCIAS.....	60
6. ANEXOS.....	64

6.1.	Anexo I: Primera cobertura LiDAR PNOA	64
6.2.	Anexo II: Segunda cobertura LiDAR PNOA.....	67
6.3.	Anexo III: Mapas de localización de las muestras de entrenamiento y validación ..	70
6.4.	Anexo IV: Resultados de las clasificaciones.....	75
6.4.1.	Otros resultados obtenidos del modelo a partir de los datos de ALS80 a 0,5 p/m2 sobre el bloque de referencia	75
6.4.2.	Otros resultados obtenidos del modelo a partir de los datos de Riegl Q-680 a 0,5 p/m2 sobre el bloque de referencia	77
6.4.3.	Otros resultados obtenidos del modelo generalista de clasificación sobre el bloque de referencia.....	79

ÍNDICE DE FIGURAS

Figura 1. Esquema de trabajo del LiDAR aerotransportado. Fuente: Vosselman & Mass (2010)	2
Figura 2. Tecnología de escaneo LiDAR y patrón resultante. Fuente: Vosselman & Mass (2010).....	3
Figura 3. Matriz de confusión para un problema multi-clase. Fuente: Krüger (2018)	7
Figura 4. Punto de suelo mal clasificado, a una diferencia de altura de 5,65 metros sobre el suelo	9
Figura 5. Punto de suelo mal clasificado, a una diferencia de altura de 14,4 metros sobre el suelo	9
Figura 6. Descarga de datos LiDAR de las dos coberturas. Fuente: CNIG (2019).....	12
Figura 7. Lotes de la primera cobertura. Fuente: IGN (2019).....	12
Figura 8. Lotes de la segunda cobertura. Fuente: IGN (2019).....	13
Figura 9. Diferencias entre un sensor multifotónico y de fotón único. Fuente: Swatantran <i>et al.</i> (2016).....	14
Figura 10. Ejemplo de ruido sobre los datos de Navarra	15
Figura 11. Pasadas realizadas. Fuente: IDENA y elaboración propia.....	16
Figura 12. Fases seguidas en la clasificación del vuelo de Navarra del 2017.....	17
Figura 13. Localización de las muestras de entrenamiento y validación. Fuente: Tracasa ...	17
Figura 14. Ejemplo de una muestra. En verde, vegetación; suelo, naranja; rojo, edificios; azul, agua y en blanco, sin clasificar. Fuente: Tracasa	17
Figura 15. Ejemplo de Box Plot y separabilidad de las clases. Fuente: Tracasa	20
Figura 16. Programa las-discrepancy2csv.....	24
Figura 17. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase suelo	25
Figura 18. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Vegetación baja	25
Figura 19. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Vegetación media.....	26
Figura 20. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Vegetación alta	26
Figura 21. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Edificios.....	26
Figura 22. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Puntos bajo el suelo	27
Figura 23. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Artefactos sobre el suelo	27
Figura 24. Gráfica de la función del parámetro DistFile1	27
Figura 25. Gráfica de la función del parámetro DistFile2	28
Figura 26. Esquema de los parámetros calculados para cada punto.....	30

Figura 27. Resumen de los resultados obtenidos	34
Figura 28. Ejemplo de la duplicación de información. Fuente: CNIG (n.d.)	36
Figura 29. Programa las-join-rgbnir-ignspain	36
Figura 30. Falso color sobre muestra de vegetación tras aplicar la información infrarroja	36
Figura 31. Ejemplo buffer de 50 metros.....	37
Figura 32. Programa las-samples2csv	41
Figura 33. Programa las-train2las	41
Figura 34. Programa las-classify2las.....	42
Figura 35. Mapa localización del bloque 602-4670 (Alfaro, La Rioja)	42
Figura 36. Clasificación precisa del bloque 602-4670. En naranja, suelo; en verde, vegetación; en naranja, suelo y en blanco, artefactos sobre el suelo	43
Figura 37. Bordos de edificios mal clasificados como vegetación alta (en verde oscuro)	43
Figura 38. Bordos de edificios bien clasificados (en rojo)	43
Figura 39. Automóviles mal clasificados como vegetación media (en verde pistacho)	44
Figura 40. Automóviles bien clasificados (en blanco)	44
Figura 41. Esquema de los modelos obtenidos y su validación	45
Figura 42. Bloque clasificado por el modelo ALS80 a 0,5 p/m ²	46
Figura 43. Ejemplo de puntos mal clasificados de edificios (en rojo) sobre suelo (en naranja)	48
Figura 44. Puntos de la clase suelo mal clasificados sobre tejados (en naranja).....	48
Figura 45. Resultado obtenido por el modelo Riegl Q-680	49
Figura 46. Puntos de la clase artefactos sobre suelo mal clasificados (en blanco) y bien clasificados (al fondo, verde pistacho).....	50
Figura 47. Puntos de edificios (en rojo) mal clasificados	50
Figura 48. Puntos de la clase edificios mal clasificados en zonas con pendiente (en rojo) ...	51
Figura 49. Puntos de la clase suelo mal clasificados sobre tejados (en naranja).....	51
Figura 50. Bloque clasificado mediante el modelo generalista de clasificación.....	53
Figura 51. Puntos de la clase 13 erróneos (en blanco).....	54
Figura 52. Ejemplo de puntos mal clasificados de edificios (en rojo) sobre suelo (en naranja)	55
Figura 53. Ejemplo de puntos de suelo (en naranja) sobre tejados altos (en rojo).....	55
Figura 54. Años de inicio de vuelo de la primera cobertura. Fuente: IGN (2019)	65
Figura 55. Sensores utilizados en la primera cobertura. Fuente: IGN (2019).....	65
Figura 56. Densidad de puntos por lote en la primera cobertura. Fuente: IGN (2019)	66
Figura 57. Años de inicio de vuelo de la segunda cobertura. Fuente: IGN (2019)	68
Figura 58. Sensores utilizados en la segunda cobertura. Fuente: IGN (2019)	68
Figura 59. Densidad de puntos de los lotes de la segunda cobertura. Fuente: IGN (2019) ..	69

Figura 60. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Galicia Oeste	70
Figura 61. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Valencia (1º cobertura)	71
Figura 62. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de La Rioja	72
Figura 63. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en los lotes de Aragón CN y Aragón SE	73
Figura 64. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Valencia (2º cobertura)	74

ÍNDICE DE TABLAS

Tabla 1. Versiones LAS. Fuente: ASPRS (2013).....	4
Tabla 2. Atributos asociados a cada punto. Fuente: ASPRS (2016).....	4
Tabla 3. Clases disponibles en las versiones LAS anteriores. Fuente: ASPRS (2003, 2005, 2008, 2010).....	6
Tabla 4. Clases disponibles en la versión LAS más actual. Fuente: ASPRS (2013).....	6
Tabla 5. Medidas de rendimiento globales para clasificaciones multiclase. Fuente: Congalton & Green (2008).....	7
Tabla 6. Medidas de rendimiento por clase utilizadas para clasificaciones multiclase. Fuente: Sokolova & Lapalme (2009).....	8
Tabla 7. Especificaciones técnicas del proyecto. Fuente: Tracasa (2018).....	15
Tabla 8. Características obtenidas por los propios puntos y por la librería PDAL. Fuente: Tracasa.....	18
Tabla 9. Características generadas a partir de las obtenidas por las CGAL y las características de cada punto. Fuente: Tracasa.....	19
Tabla 10. Ajuste de los parámetros del algoritmo utilizado. Fuente: Tracasa.....	21
Tabla 11. Diferentes medidas a calcular a partir de los propios datos.....	24
Tabla 12. Matriz de costes: Diferencia de clases.....	25
Tabla 13. Matriz de costes: Clase mayoritaria de los vecinos en la clasificación del modelo.....	28
Tabla 14. Matriz de costes: Clase mayoritaria de los vecinos en la clasificación de referencia.....	29
Tabla 15. Matriz de costes: Diferencia de clases de las diferentes vecindades.....	29
Tabla 16. Medidas básicas.....	31
Tabla 17. Tipo de error respecto a la puntuación obtenida.....	31
Tabla 18. Medidas por tipo de error.....	31
Tabla 19. Medidas de tipos de error por clase (totales).....	32
Tabla 20. Medidas de tipos de error por clase (en porcentajes).....	32
Tabla 21. Matriz de confusión por clases.....	33
Tabla 22. Estadísticas obtenidas a partir de la matriz de confusión. Fuente: Congalton & Green (2008).....	33
Tabla 23. Ejemplo de tabla para la clase 2.....	33
Tabla 24. Errores groseros.....	34
Tabla 25. Organización de la información RGBI.....	36
Tabla 26. Tabla-resumen de la obtención de muestras.....	38
Tabla 27. Número de puntos para las muestras ALS80 a 0,5 p/m ²	38
Tabla 28. Muestras de validación para ALS80 0.5 p/m ² . (En la figura 59, en rojo).....	38
Tabla 29. Muestras de entrenamiento para ALS80 0.5 p/m ² . (En la figura 59, en azul).....	38
Tabla 30. Número de puntos para las muestras ALS80 a 1 p/m ²	39

Tabla 31. Muestras de validación para ALS80 1 p/m ² . (En la figura 60, en rojo).....	39
Tabla 32. Muestras de entrenamiento para ALS80 1 p/m ² . (En la figura 60, en azul)	39
Tabla 33. Número de puntos para las muestras ALS80 a 2 p/m ²	39
Tabla 34. Muestras de validación para ALS80 2 p/m ² . (En la figura 61, en rojo).....	39
Tabla 35. Muestras de validación para ALS80 2 p/m ² . (En la figura 61, en azul)	39
Tabla 36. Número de puntos para las muestras Riegl Q-680	40
Tabla 37. Muestras de validación para Riegl Q-680 (En la figura 62, en rojo)	40
Tabla 38. Muestras de entrenamiento para Riegl Q-680 (En la figura 62, en azul)	40
Tabla 39. Número de puntos para las muestras Riegl Q-780	40
Tabla 40. Muestras de validación para Riegl Q-680 (En la figura 63, en rojo)	40
Tabla 41. Muestras de entrenamiento para Riegl Q-780 (En la figura 63, en azul)	40
Tabla 42. Resultados de las muestras de entrenamiento al obtener el modelo de los datos de ALS80 a 0,5 p/m ²	46
Tabla 43. Resultados de las muestras de entrenamiento al obtener el modelo de los datos de Riegl Q-680 a 0,5 p/m ²	46
Tabla 44. Errores por clase	47
Tabla 45. Porcentaje correspondiente a cada tipo de error por clase	47
Tabla 46. Porcentaje de errores según el tipo de error.....	48
Tabla 47. Errores groseros.....	49
Tabla 48. Errores por clase	50
Tabla 49. Porcentaje correspondiente a cada tipo de error por clase	51
Tabla 50. Porcentaje de errores según el tipo de error.....	52
Tabla 51. Errores groseros.....	52
Tabla 52. Resultados de las muestras de entrenamiento del modelo obtenido a partir de todas las muestras.....	53
Tabla 53. Errores por clase	54
Tabla 54. Porcentaje correspondiente a cada tipo de error por clase	54
Tabla 55. Porcentaje de errores según el tipo de error.....	55
Tabla 56. Errores groseros.....	56
Tabla 57. Resumen de los resultados obtenidos	57
Tabla 58. Información detallada de los lotes (Primera cobertura) Fuente: IGN (2019).....	64
Tabla 59. Información detallada de los lotes (Segunda cobertura) Fuente: IGN (2019).....	67
Tabla 60. Tipo de error por clase (en números enteros).....	75
Tabla 61. Puntos erróneos de la clase 2 respecto a las otras clases.....	75
Tabla 62. Puntos erróneos de la clase 3 respecto a las otras clases.....	75
Tabla 63. Puntos erróneos de la clase 4 respecto a las otras clases.....	75

Tabla 64. Puntos erróneos de la clase 5 respecto a las otras clases.....	75
Tabla 65. Puntos erróneos de la clase 6 respecto a las otras clases.....	76
Tabla 66. Puntos erróneos de la clase 11 respecto a las otras clases.....	76
Tabla 67. Puntos erróneos de la clase 13 respecto a las otras clases.....	76
Tabla 68. Matriz de confusión.....	76
Tabla 69. Error de omisión por clase.....	76
Tabla 70. Error de comisión por clase.....	76
Tabla 71. Tipo de error por clase (en números enteros).....	77
Tabla 72. Puntos erróneos de la clase 2 respecto a las otras clases.....	77
Tabla 73. Puntos erróneos de la clase 3 respecto a las otras clases.....	77
Tabla 74. Puntos erróneos de la clase 4 respecto a las otras clases.....	77
Tabla 75. Puntos erróneos de la clase 5 respecto a las otras clases.....	77
Tabla 76. Puntos erróneos de la clase 6 respecto a las otras clases.....	77
Tabla 77. Puntos erróneos de la clase 11 respecto a las otras clases.....	77
Tabla 78. Puntos erróneos de la clase 13 respecto a las otras clases.....	78
Tabla 79. Matriz de confusión.....	78
Tabla 80. Error de omisión por clase.....	78
Tabla 81. Error de comisión por clase.....	78
Tabla 82. Tipo de error por clase (en números enteros).....	79
Tabla 83. Puntos erróneos de la clase 2 respecto a las otras clases.....	79
Tabla 84. Puntos erróneos de la clase 3 respecto a las otras clases.....	79
Tabla 85. Puntos erróneos de la clase 4 respecto a las otras clases.....	79
Tabla 86. Puntos erróneos de la clase 5 respecto a las otras clases.....	79
Tabla 87. Puntos erróneos de la clase 6 respecto a las otras clases.....	79
Tabla 88. Puntos erróneos de la clase 11 respecto a las otras clases.....	79
Tabla 89. Puntos erróneos de la clase 13 respecto a las otras clases.....	80
Tabla 90. Matriz de confusión.....	80
Tabla 91. Error de omisión por clase.....	80
Tabla 92. Error de comisión por clase.....	80

1. Introducción

1.1. Preámbulo

Actualmente, el láser escáner aerotransportado (ALS LiDAR) es una de las tecnologías más utilizadas para realizar modelos tridimensionales del terreno, gracias a su precisión y resolución. La tecnología LiDAR, en constante desarrollo, avanza en algunos aspectos, como es el de la clasificación automatizada de los puntos. A pesar de ello, aún existen áreas en las que se debe mejorar, como la verificación de la clasificación de los puntos. Esta última fase resulta uno de los puntos clave para asegurar la calidad de los diferentes productos finales que se elaboran a partir de esta técnica, como son los siguientes (Baltsavias, 1999a):

- Modelo Digital del Terreno (MDT), obtenido a partir de la interpolación de los puntos de suelo.
- Modelos Digitales de Superficie (MDS), obtenidos a partir de la interpolación de los primeros pulsos, que corresponden a la envolvente de los objetos presentes sobre el terreno.
- Modelo Digital de Alturas, obtenido a partir de la resta de las dos anteriores.

Para realizar cualquier producto, es necesario una buena clasificación de los puntos. Tras el trabajo realizado en la clasificación de los datos de la segunda cobertura de la Comunidad Foral de Navarra, una de las necesidades de la empresa Tracasa ha sido la de lograr una manera de agilizar la evaluación de los distintos modelos generados. Hasta ahora, al generar un modelo de clasificación, éste se ha evaluado de manera analítica y visual, si bien la conclusión final no tiene por qué coincidir en ambos casos, ya que la evaluación analítica no tiene en cuenta la gravedad de cada error.

Además, debido a la disponibilidad de datos LiDAR existentes para todo el territorio en el marco del Plan Nacional de Ortofotografía Aérea desde el año 2009, se dispone de datos para todo el estado. Sin embargo, no existe un modelo de clasificación general para todos ellos, ya que los datos provienen de distintos sensores y densidades, con diferentes características. A causa de ello, resulta necesario investigar para tratar de dar con un modelo generalista de clasificación que proporcione resultados adecuados en todos los casos.

1.2. Antecedentes

1.2.1. Tecnología LiDAR

Light Detection And Ranging (LiDAR), también conocido como *Laser Scanning* o *Laser Detection And Ranging* (LaDAR), es una técnica de teledetección que utiliza la luz, en forma de pulsos láser de corta duración, para medir el rango o distancia a una superficie (Wehr & Lohr, 1999). Se trata de un sensor activo, que proporciona los datos de rango como puntos en 3D (Mallet & Bretar, 2009), a partir del tiempo de retardo medido por el sensor:

$$R = c \frac{t}{2} \quad (\text{Ecuación 1})$$

Donde R es la distancia entre el sensor y el objeto, t es el tiempo medido y c es la velocidad de la luz ($300,000 \text{ km s}^{-1}$) (Baltsavias, 1999b).

Gran parte de los sensores LiDAR también son capaces de registrar el valor de intensidad para cada punto. El valor de intensidad es proporcional a la amplitud del pulso recibido (Hyypä, 2011) y representa las propiedades de dispersión del objeto o superficie observado en la longitud de onda a la que opera el sensor (Scaioni *et al.*, 2018).

Además del propio pulso de retorno láser, en un vuelo LiDAR se registran la posición y la orientación del sensor utilizando un sistema de posicionamiento global (GNSS) y un sistema inercial de navegación (INS), por lo que los datos constituyen un conjunto de coordenadas X, Y y Z (i.e., nube de puntos) que representan la superficie desde la cual se reflejaron los pulsos (Vosselman & Mass, 2010).

Este tipo de sensores operan generalmente en la región del infrarrojo cercano (NIR, 800-2500 nm) y en algunos casos, en la región de la banda del verde (497-570 nm). Al tratarse de un sistema activo, éste emite su propio flujo electromagnético, por lo que no se ve afectado por la falta de luz solar o diferentes condiciones atmosféricas (Baltsavias, 1999a).

Este trabajo se centrará en el LiDAR aerotransportado, que consiste en un sensor incorporado en una plataforma móvil, como un helicóptero, avión o dron, que barre el área de estudio (Figura 1).




Figura 1. Esquema de trabajo del LiDAR aerotransportado. Fuente: Vosselman & Mass (2010)

Los pulsos láser emitidos por el sensor se reflejan en la superficie o sobre un objeto y regresan al mismo como un único retorno o como retornos múltiples. Esto varía dependiendo de las características de los objetos que se encuentran sobre la superficie:

- En el caso de una superficie opaca, como es el caso del suelo o de las cubiertas de edificios, el pulso retorna sin ningún problema, solo habrá un retorno.
- En zonas con agua, el pulso emitido por los sensores que operan a la longitud de onda del NIR sufre una reflexión especular, por lo que no vuelve al sensor; en estas zonas no se obtiene información. A pesar de ello, existen sensores LiDAR batimétricos que pueden penetrar en el agua entre 1.5 y 60 metros. Este tipo de sensores operan generalmente en la longitud de onda del verde y están diseñados para lanzar y registrar un retorno doble; el primero desde la superficie del agua y el segundo desde el fondo (Wang & Philpot, 2007).
- En objetos en los que puede penetrar el pulso, como es el caso de la vegetación, devolverá varios retornos. El número total dependerá del número de objetos (hojas, ramas, etc.) se el pulso encuentre en su trayectoria. Por lo tanto, el registro del primer pulso permite describir la parte más alta del objeto, mientras que el último retorno, en la mayoría de los casos nos ofrecerá información sobre la superficie del suelo (National Oceanic and Atmospheric Association, 2012).

Existen dos tipos de láser que miden la distancia entre el sensor y el objeto:

- **Sistemas de pulso discretos:** La distancia es determinada mediante la medición del tiempo desde que se emite y se recibe la señal, de manera discreta. Este tipo de sensores, normalmente, obtienen 1-4 retornos por pulso (Korpela *et al.*, 2009).
- **Sistemas de onda continua (*full-waveform*):** El sistema de detección convierte los pulsos recibidos en una onda continua, mostrando la energía de retorno obtenida de los distintos elementos de la cubierta para cada parte infinitesimal del pulso emitido (Mallet & Bretar, 2009).

Además, existen diferentes tipos de sensor en función de la tecnología, que obtienen distintos patrones de escaneo (Vosselman & Mass, 2010):

- Espejo oscilante:** El espejo giratorio dirige el pulso láser en ambas direcciones, por lo que se obtiene un patrón en zig-zag. Es uno de los patrones más habituales.
- Prisma rotatorio:** El prisma desvía el haz de luz en una sola dirección, por lo que se obtiene un patrón de líneas paralelas.
- Escáner de Palmer:** El haz láser es dirigido por dos espejos que producen un patrón elíptico.
- Fibra óptica:** el haz láser es desviado a las fibras laterales que se sitúan alrededor del eje. Se obtiene un patrón de pequeñas circunferencias solapadas.

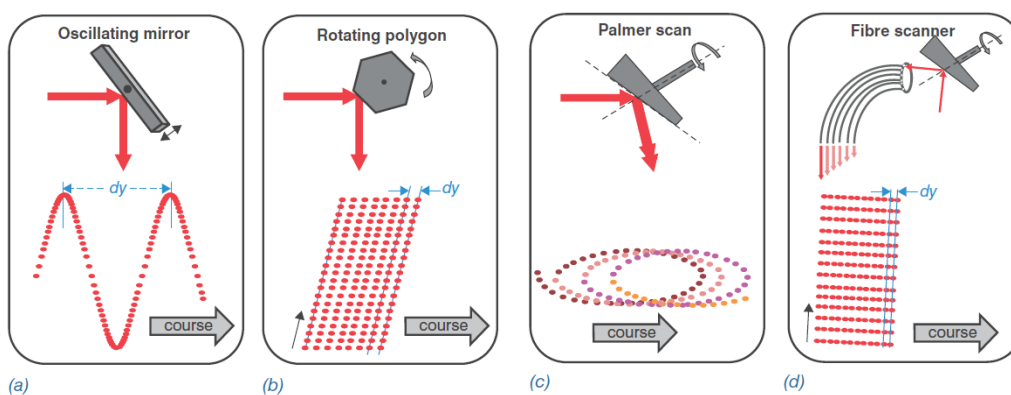


Figura 2. Tecnología de escaneo LiDAR y patrón resultante. Fuente: Vosselman & Mass (2010)

1.1.1.1 Formato de datos LiDAR

El formato de datos LiDAR considerado estándar es el formato LAS (LASer), desarrollado por la *American Society of Photogrammetry And Remote Sensing* (ASPRS). Este fue creado como alternativa a los sistemas de propiedad y a los ficheros ASCII, con el fin de facilitar el intercambio de datos tridimensionales (ASPRS, 2013).

Desde el año 2003, la ASPRS ha variado en un total de 4 veces el formato LAS; gracias a ello se han podido incluir distintas mejoras. Desde el 14 de noviembre del año 2011, la versión más reciente es la 1.4. En la tabla 1, se muestra su evolución.

Tabla 1. Versiones LAS. Fuente: ASPRS (2013)

Versión	Fecha de lanzamiento
LAS 1.0	9 de mayo del 2003
LAS 1.1	7 de marzo del 2005
LAS 1.2	9 de febrero del 2008
LAS 1.3	24 de octubre del 2010
LAS 1.4	14 de noviembre del 2011

El formato contiene datos binarios repartidos en diferentes bloques (ASPRS, 2013):

- Bloque de encabezado público:** Contiene datos genéricos, como la versión, fecha de creación del fichero, X, Y y Z máximos y mínimos, número de puntos, etc.
- Registros de longitud variable** (sus siglas en inglés VLR): Contiene datos de distinta naturaleza.
- Registros de la nube de puntos:** Se trata del bloque central, donde se guarda la información asociada a cada punto. En la siguiente tabla (2), se muestran los diferentes ítems asociados a cada punto y su descripción.

Tabla 2. Atributos asociados a cada punto. Fuente: ASPRS (2016)

Item	Descripción
X	Coordenada X
Y	Coordenada Y
Z	Coordenada Z
Intensity	Intensidad. Cantidad de energía reflejada por el retorno. Se codifica a 8 bits (0-255). Este dato es opcional.
Return number	Número de retorno del punto. Varía de 1 (el primero) a 5
Number of returns	Número total de retornos recibidos del pulso que genera el punto
Scan direction flag	Dirección de escaneo. Sentido en el que se mueve el espejo del escáner
Edge of flight line	Borde de la línea de vuelo. Si ese punto se encuentra en el borde de la pasada, su valor será 1 y si no, 0
Classification	Conjunto estándar de códigos predefinidos que tienen el objetivo de etiquetar cada punto
Scan angle	Ángulo de escaneo del punto. Valor entre -90 y 90 (en grados) que define el haz láser respecto al nadir (0°)
User data	Datos del usuario a rellenar
Point source ID	Identificador de la pasada

A partir de la versión LAS 1.4, existen 11 distintos formatos de registro de los puntos. Los distintos formatos difieren en los campos de datos disponibles:

- **Formato 0:** Formato básico.
- **Formato 1:** Se incluye los datos del formato 0 y el tiempo GPS.
- **Formato 2:** Se incluye los datos del formato 0 y los canales RGB.
- **Formato 3:** Se incluye los datos del formato 0, tiempo GPS y los canales RGB.
- **Formato 4:** Formato utilizado para sensores Full-waveform.
- **Formato 5:** Se incluyen los parámetros del formato 4, tiempo GPS y los canales RGB
- **Formato 6:** Formato con más bits de información disponible, dirigido a sensores de hasta 15 retornos por pulso, con un mayor número de clases y mayor precisión en el ángulo de escaneo. También se incluye el tiempo GPS.
- **Formato 7:** Se incluyen los datos del formato 6 y los canales RGB.
- **Formato 8:** Se incluyen los datos del formato 7 y el canal NIR.
- **Formato 9:** Formato 6 para sensores Full-waveform.
- **Formato 10:** Formato 7 para sensores Full-waveform.

4. Registros de la longitud variable extendida (EVLRL): Es idéntico al bloque VLR, pero este último puede albergar mayor cantidad de información.

Gran parte de los ficheros LAS suelen ocupar mucho espacio; para paliar este problema, han surgido variantes del formato LAS de forma comprimida:

- **LAZ:** Formato desarrollado por Martin Isenburg con el fin de comprimir los datos del formato ASPRS LAS. Este formato posee licencia LGPL (GNU Lesser General Public License) y se ha integrado en diferentes bibliotecas de código abierto como LASlib y libLAS. Tras la compresión, los ficheros LAZ ocupan aproximadamente entre 7-25% del tamaño del archivo original LAS (Isenburg, 2013).
- **zLAS:** Formato propio de ESRI, disponible a partir de la versión de ArcGIS 10.2.1, que posee ratios de compresión similares al formato LAZ (ESRI, 2014; Rapidlasso GmbH, 2013).

1.1.1.2 Clasificación de puntos LiDAR

Cada punto LiDAR puede clasificarse según la cubierta desde la que proviene. Esta clasificación es opcional; por lo tanto, encontraremos tanto archivos LAS/LAZ clasificados como sin clasificar. Esta clasificación puede realizarse de manera manual mediante software específicos para ello o aplicar distintos algoritmos de clasificación automática disponibles, tanto disponibles gratuitamente (por ejemplo, el algoritmo *lasclassify* implementado en la librería LAsTools) como comerciales (por ejemplo, los algoritmos implementados de TerraScan). La mayoría se basa en establecer reglas de decisión a partir de información sobre el número de retorno, la intensidad y la información de los puntos vecinos. A pesar de ello, el gran problema de estos últimos es que son poco transparentes.

Las diversas clases han sido definidas por el estándar LAS, mediante números enteros dentro del fichero LAS. Dependiendo de la versión LAS utilizada, se puede apreciar la diferencia existente en el número de categorías disponibles. En el formato más reciente (1.4), existen un total de 256 posibles valores. En las tablas 3 y 4, se muestran los valores de clasificación utilizados por el estándar en las diferentes versiones disponibles a lo largo del tiempo:

Tabla 3. Clases disponibles en las versiones LAS anteriores. Fuente: ASPRS (2003, 2005, 2008, 2010)

Clase	LAS versión 1.1, 1.2 y 1.3
0	Nunca clasificado
1	No clasificado
2	Suelo
3	Vegetación baja
4	Vegetación media
5	Vegetación alta
6	Edificaciones
7	Punto bajo (<i>Low Point</i>)
8	<i>Model Key-point (mass point)</i>
9	Agua
10	Reservado
11	Reservado
12	Solape
13-31	Reservado

Tabla 4. Clases disponibles en la versión LAS más actual. Fuente: ASPRS (2013)

Clase	LAS versión 1.4
0	Nunca clasificado
1	No clasificado
2	Suelo
3	Vegetación baja
4	Vegetación media
5	Vegetación alta
6	Edificaciones
7	Punto bajo (<i>Low Point</i>)
8	Reservado
9	Agua
10	Vía férrea
11	Carretera
12	Reservado
13	Tendido
14	Cable de tendido eléctrico
15	Torre eléctrica
16	Conector de tendido
17	Cubierta de punto
18	Punto alto
19-63	Reservado
64-255	Definido por el usuario

1.2.2. Estado del arte

Actualmente, durante el procesamiento de datos LiDAR, la mayoría de las tareas se realizan por métodos automáticos, debido a la naturaleza de los datos (Ivanova & Galo, 2017). Una de las tareas más importantes es la de la clasificación de los puntos LiDAR, que lleva asociada una evaluación o validación de los resultados obtenidos. Hasta la fecha, para abordar la fase de clasificación, el aprendizaje automático (*Machine Learning*) es una de las técnicas más utilizadas, de la que encontramos diversos trabajos. En cambio, no existe literatura que trate específicamente sobre la validación de la clasificación de nubes de puntos LiDAR; en todo caso, lo encontramos como uno de los apartados de los estudios que tienen como objetivo la clasificación.

En la mayoría de este tipo de estudios se utilizan procedimientos estándar sin llegar a proponer novedades. En estos casos, la forma general utilizada para evaluar cualquier clasificación se basa en la matriz de confusión (Figura 3): Se trata de una matriz de m filas por m columnas (m es igual al número total de clases) en la que una entrada $c_{j,i}$ indica el número de ejemplos que se han asignado a la clase c_j cuando la clase correcta es c_i (Chuvieco, 1996).

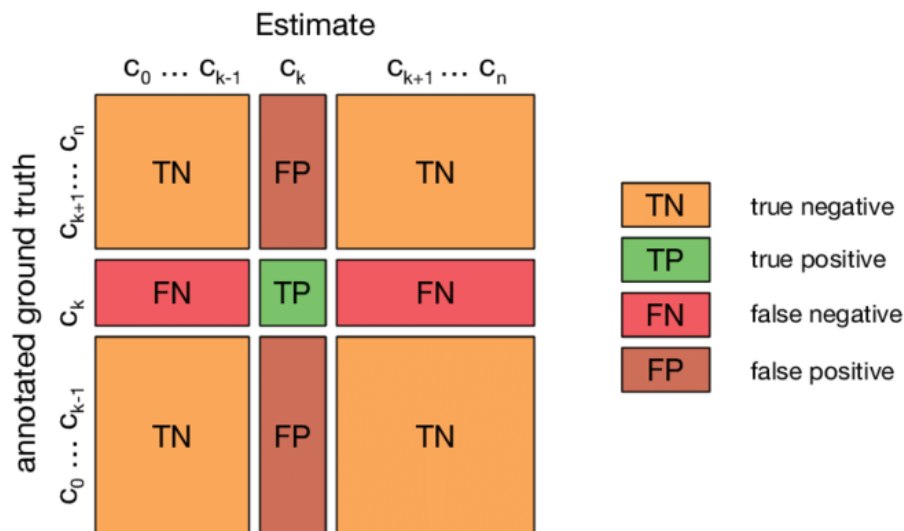


Figura 3. Matriz de confusión para un problema multi-clase. Fuente: Krüger (2018)

A partir de la matriz de confusión, es posible calcular distintas métricas que dan una idea del resultado de la clasificación. En las tablas 5 y 6 se muestran unas de las medidas de rendimiento más utilizadas (Congalton & Green, 2008; Sokolova & Lapalme, 2009).

Tabla 5. Medidas de rendimiento globales para clasificaciones multiclase. Fuente: Congalton & Green (2008)

Nombre	Fórmula	Descripción
Fiabilidad global	$FG = \frac{\sum_{i,j=1}^n c_{i=j}}{\sum_{i,j=1}^n c_{i,j}}$	Porcentaje de puntos correctamente clasificados respecto al total de puntos verificados.
Estadístico Kappa	$k = \frac{N \sum_{i=1}^n c_{ii} - \sum_{i=1}^n c_{i+} c_{+i}}{N^2 - \sum_{i=1}^n c_{i+} c_{+i}}$	Grado de fiabilidad debida a la exactitud de la clasificación, prescindiendo de otros factores de naturaleza aleatoria.

Tabla 6. Medidas de rendimiento por clase utilizadas para clasificaciones multiclase. Fuente: Sokolova & Lapalme (2009)

Nombre	Fórmula	Descripción
Precision_i	$Precision = \frac{\sum_{j=1}^l c_{ii}}{\sum_{j=1}^l (c_{ii} + c_{ji})}$	Proporción de los ejemplos clasificados en una clase que realmente pertenecen a esa clase.
Recall_i	$Recall = \frac{\sum_{j=1}^l c_{ii}}{\sum_{j=1}^l (c_{ii} + c_{ij})}$	Proporción de los ejemplos de muestra de una clase que han sido bien clasificados.
F-measure_i	$F - measure = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$	Eficacia del clasificador al identificar ejemplos positivos de una clase.

En el trabajo realizado por Lodha *et al.* (2007) se clasificaron las clases suelo, vegetación baja, carreteras y edificios utilizando únicamente características propias de la nube de puntos. La posterior validación de los modelos obtenidos se realizó tras calcular la medida de Fiabilidad Global. En el trabajo realizado por Chehata *et al.* (2009), en cambio, la clasificación se realizó a partir de características relacionadas con la altura, intensidad, eigenvalores y características obtenidas en el propio vuelo LiDAR. En este caso, se optó por clasificar suelo natural, suelo artificial, vegetación y edificios. No obstante, la validación de los modelos obtenidos se realizó de forma similar a Lodha *et al.* (2007), calculando el error a partir de una matriz de confusión.

Parte de los trabajos de clasificación automática en el ámbito del LiDAR tienen como objetivo la clasificación de edificios. Por ejemplo, en el trabajo realizado por Henn *et al.* (2013), los edificios fueron clasificados por tipologías, a partir de diversas características como la inclinación o el ángulo del azimut de los puntos. En este caso, gracias a la matriz de confusión obtenida, se calcularon parámetros como *Precision* y *Recall* con el fin de validar el modelo. Para finalizar, en el estudio realizado por Lu *et al.* (2014), los edificios fueron clasificados por tipologías a partir de características como los atributos de los *shapes* utilizados, la relación espacial entre edificios y la relación espacial de esos edificios con las características del terreno. En este caso, el modelo obtenido fue evaluado mediante las medidas de Fiabilidad Global y Kappa; esta última también se obtiene a partir de la matriz de confusión.

Sin embargo, en el trabajo realizado por Sithole & Vosselman (2004), encontramos una evaluación no basada en las métricas comentadas en los estudios anteriores. En este caso, se realiza una evaluación semi-cualitativa: El resultado en 17 características se divide en 3 clases (Bueno, justo o malo), según el porcentaje de eficacia obtenido.

A pesar de ello, en los casos descritos, todos los puntos tienen el mismo impacto en las medidas de rendimiento, sin tener en cuenta la gravedad del error. Esto resulta problemático, ya que en función de su gravedad un punto mal clasificado puede tener consecuencias muy distintas en los productos derivados obtenidos a partir de la nube de puntos, como Modelos Digitales del Terreno (MDT) o de Superficie (MDS). Por ejemplo, un punto de vegetación mal clasificado como suelo tendrá unas consecuencias mucho más graves en el MDT resultante si es un punto elevado cercano a la copa del árbol que si es un punto bajo más cercano al suelo; como se puede apreciar en las figuras 4 y 5. Un único punto mal clasificado, independientemente de su posición y naturaleza, tiene el mismo impacto en las medidas de rendimiento, sin embargo, una valoración visual permite descubrir que el error obtenido en la

figura izquierda es menor, ya que se traduce en una menor variación del MDT resultante de los puntos LiDAR de suelo.




Figura 4. Punto de suelo mal clasificado, a una diferencia de altura de 5,65 metros sobre el suelo




Figura 5. Punto de suelo mal clasificado, a una diferencia de altura de 14,4 metros sobre el suelo

Como el ejemplo mostrado anteriormente, su efecto en los indicadores de Fiabilidad Global, Kappa o en los indicadores por clase es exactamente igual. Por tanto, es necesario mejorar los procesos de evaluación o validación de las clasificaciones incorporando este tipo de información.

1.3. Objetivos

En este Trabajo Fin de Máster se quiere abordar el siguiente objetivo general:

- La definición de una metodología de validación que permita de forma automática evaluar cualquier clasificación respondiendo a la necesidad de descubrir errores, que puedan repercutir gravemente en el resultado final. Además, se desea que la metodología desarrollada pueda ser aplicable a nubes de puntos obtenidas por todo tipo de sensores y densidades de puntos.

La consecución de este objetivo lleva asociado otro segundo, que es doble. Gracias a la disponibilidad de datos, se quiere realizar lo siguiente:

- Se quiere analizar y evaluar la clasificación de datos LiDAR de otras fuentes, que procedan de diferentes sensores y especificaciones, con la configuración de un modelo de clasificación genérico desarrollado para los datos del vuelo de Navarra en 2017.
- Se quiere generar un modelo generalista de clasificación a partir de muestras de aprendizaje de distintos datos, de sensores y densidades diferentes.

Todas estas clasificaciones serán evaluadas mediante la herramienta generada en el primer objetivo.

2. MATERIALES Y MÉTODOS

2.1. Introducción

En este apartado se muestran los materiales y métodos utilizados en el trabajo, que se divide en dos grandes bloques; por un lado, se incluye la información necesaria utilizada como base (punto 2.2.), y por otro lado, se describe minuciosamente el proceso llevado a cabo con el fin de cumplir los objetivos propuestos (punto 2.3).

Además, el punto 2.3. se ha dividido en dos fases; por un lado, la metodología seguida en la generación del validador de la clasificación de los puntos LiDAR y, por otro lado, los pasos a seguir con el fin de generar diferentes modelos de clasificación a partir de datos con sensores y densidades concretas. Todas las herramientas utilizadas en estas dos fases han sido desarrolladas por Álvaro Huarte y Mikel Galar para la empresa Tracasa.

2.2. Base del trabajo

2.2.1. Proyecto PNOA

Uno de los objetivos principales de la Directiva europea INSPIRE (*Infrastructure for Spatial Information in the European Community*) es hacer disponible para todos los públicos diferente información geográfica de calidad. Tanto los recubrimientos de ortoimágenes como los Modelos Digitales de Elevaciones obtenidos a partir de los datos LiDAR forman parte de los *datos básicos de referencia* que recoge la Directiva (Parlamento Europeo, 2007).

En este marco se encuadra el nacimiento en el año 2004 del Plan Nacional de Ortofotografía Aérea (PNOA). El objetivo de este proyecto es obtener información geográfica para todo el territorio español de manera homogénea, mediante un esquema de producción descentralizada, en el que las diferentes comunidades autónomas generen su propia información acorde a unas especificaciones técnicas comunes (IGN, 2019).

Este plan, gestionado y liderado por el Instituto Geográfico Nacional (IGN) y el Centro Nacional de Información Geográfica (CNIG), es resultante de la colaboración y cofinanciación entre diferentes organismos:

- Ministerio de Fomento (por medio del IGN y el CNIG)
- Ministerio de Agricultura, Alimentación y Medio Ambiente (por medio de la Dirección General del Agua, las Confederaciones Hidrográficas y el Fondo Español de Garantía Agraria)
- Ministerio de Hacienda y Administraciones Públicas (por medio de la Dirección General del Catastro)
- Las 17 diferentes comunidades autónomas

En el año 2008, se inició la captura de datos LiDAR en territorio estatal, con el fin de obtener modelos digitales de gran precisión. Esta primera cobertura se completó en el 2015. En ese mismo año, se comenzó de manera simultánea con la toma de datos de la segunda cobertura (aún sin finalizar).

Toda la información obtenida hasta la actualidad se encuentra disponible en la web del CNIG, que suministra los datos tras haber sido procesados en bloques de 2x2 km en formato LAZ. El sistema geodésico de referencia para los datos peninsulares, Ceuta, Melilla y las Islas Baleares es el ETRS89, en el caso de Canarias, en cambio, es el REGCAN95 (ambos compatibles).



Figura 6. Descarga de datos LiDAR de las dos coberturas. Fuente: CNIG (2019)

2.2.1.1. Primera cobertura (2008-2015)



Figura 7. Lotes de la primera cobertura. Fuente: IGN (2019)

Esta primera cobertura comenzó en Cataluña en abril del año 2008 y finalizó en el suroeste de Andalucía en 2015. Las especificaciones generales fueron las siguientes:

- Densidad mínima: 0,5 p/m²
- Precisión altimétrica de la nube de puntos: RMSEz ≤ (0,2-0,4) metros
- Precisión planimétrica de la nube de puntos: RMSEz ≤ 0,3 metros

Como se puede apreciar en la información que se muestra en la tabla 58, junto a las figuras 54, 55 y 56 (Apartado 6.1), en esta cobertura se utilizaron 3 sensores distintos, en la mayoría de casos, los ALS50 y 60 de Leica, y el Riegl LMS-Q680. Todas las CCAA publicaron sus datos a la densidad mínima exigida.

2.2.1.2. Segunda cobertura (2015-)

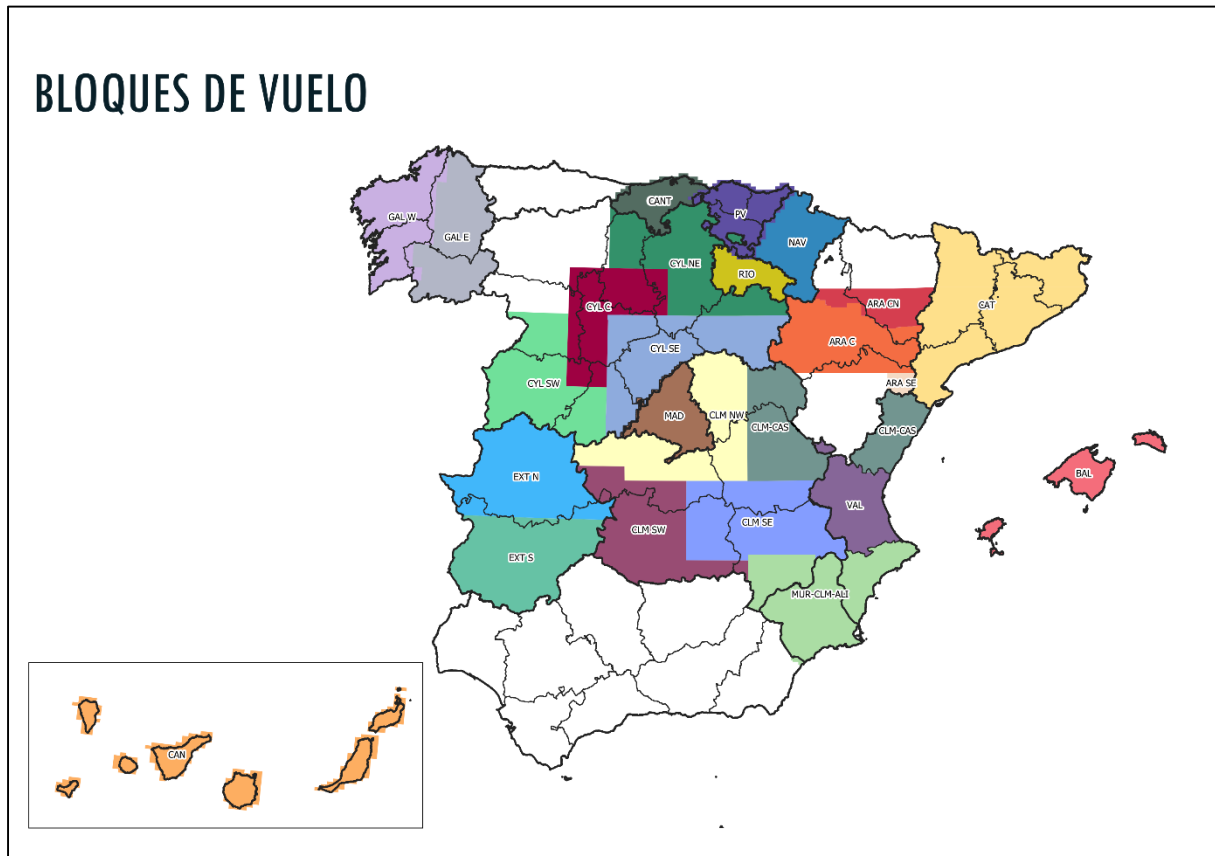


Figura 8. Lotes de la segunda cobertura. Fuente: IGN (2019)

Hasta el año 2019, han sido planeados 24 lotes; sobre 19 lotes ya ha sido realizado el vuelo, de los cuales, se han publicado íntegramente 10 en la página de descargas del CNIG¹. El primer vuelo se realizó en el lote que cubre la parte oeste de Galicia en el mismo año que terminó la primera cobertura. Actualmente, el último lote completado es el que ocupa la comunidad de Cantabria. En esta cobertura, las especificaciones han sido las siguientes:

- Densidad mínima: 1 p/m²
- Precisión altimétrica de la nube de puntos: RMSEz ≤ (0,2-0,4) metros
- Precisión planimétrica de la nube de puntos: RMSEz ≤ 0,3 metros

A pesar de ello, como se puede ver en la información que se muestra en la tabla 59, junto a las figuras 57, 58 y 59 (Apartado 6.2), en algunos casos no se han cumplido algunos criterios como la densidad mínima; en 7 lotes es menor de 1 p/m². En algunos casos, se supera, llegando a los 14 puntos en Navarra.

¹ Los lotes publicados íntegramente son GAL W, GAL E, MAD, RIO, ARA C, ARA CN, ARA SE, CAT, VAL y MUR-CLM-ALI.

En esta cobertura, se han utilizado más sensores:

- Leica: ALS50, ALS60, ALS70-HP, ALS80, SPL100
- Riegl: LMS-Q780, LMS-Q1560

2.2.2. Segunda cobertura de Navarra: Vuelo y clasificación

En el marco del proyecto PNOA, el Gobierno de Navarra licitó en 2017 la actualización de la cobertura LiDAR de la Comunidad Foral de Navarra. El proyecto fue adjudicado por Tracasa al Grupo Air-Med con la colaboración de COWI y Leica Geosystems.

Esta segunda cobertura supuso un proyecto pionero en Europa, debido a que se utilizó por primera vez el sensor de fotón único *Single Photon LiDAR 100* (SPL100) de la empresa Leica Geosystems. Esta tecnología, de origen militar, fue adquirida por la empresa en el año 2016, tras la compra de la compañía Sigma Space. La principal característica que hace diferente a este sensor es que éste divide el haz láser en una matriz de 10x10, obteniendo así 100 pequeños pulsos láser de menor energía, que al obtener los retornos actúa como un sistema de pulso discretos. Gracias a la temprana recuperación del canal (unos 1.6 nanosegundos) es posible obtener múltiples mediciones de rango. La combinación de estas dos características permite a este tipo de sensores nubes de puntos de gran densidad, de manera más rápida que otros sistemas LiDAR (Swatantran *et al.*, 2016).

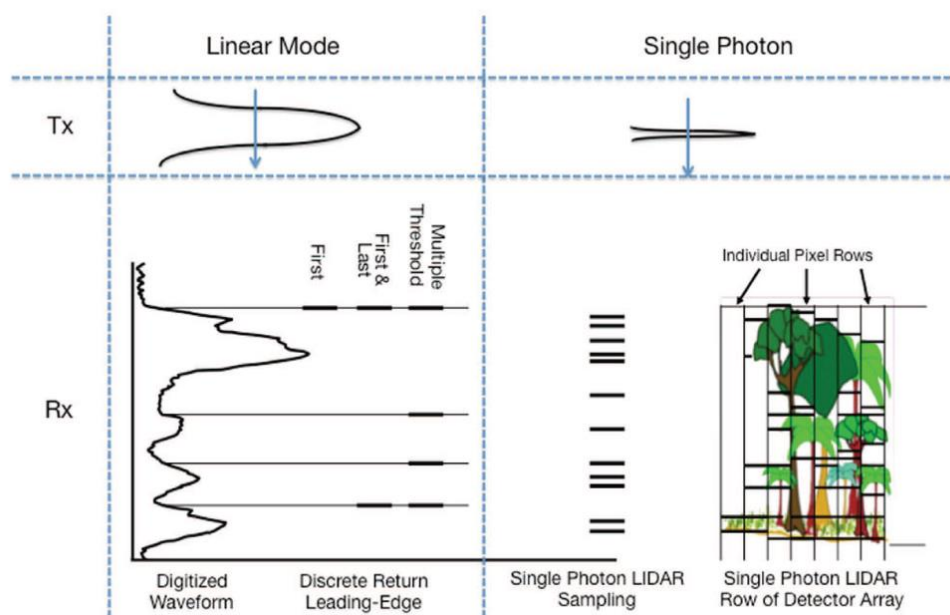


Figura 9. Diferencias entre un sensor multifotónico y de fotón único. Fuente: Swatantran *et al.* (2016)

Este tipo de sensores operan en la longitud de onda verde (532 nm), debido a que la tecnología de detectores de fotón único aún no está disponible para la longitud de onda NIR. La ventaja principal de operar en la banda del verde es que cabe la posibilidad de penetrar en zonas con agua hasta profundidades de 3 metros. Esto resulta interesante para la realización de estudios hidráulicos, geomorfológicos, etc. (Swatantran *et al.*, 2016) En cambio, las desventajas principales de operar a estas longitudes de onda son dos:

- No son ideales para realizar estudios de vegetación: La resistencia de la hoja se reduce más en el visible que en el infrarrojo cercano (Swatantran *et al.*, 2016).

- Mayor sensibilidad al ruido solar de fondo: Se producen retornos de origen solar, por lo que los datos son mucho más ruidosos (Degnan & Field, 2014). En el vuelo realizado de Navarra, el 16,84% de los puntos se han identificado como ruido (e.g., Fig 10).




Figura 10. Ejemplo de ruido sobre los datos de Navarra

La configuración de este sensor es cónica, que se traduce en un patrón circular de entre 1 y 3 kilómetros sobre el terreno. Esto dependerá de la altura de vuelo, que normalmente se sitúa a altitudes entre los 2000 y 4000 metros. Debido a estas características, además de su capacidad de dividir un pulso en 100 partes (teniendo en cuenta que puede generar hasta 60000 pulsos por segundo), este sensor es capaz de obtener 6 millones de puntos por segundo, logrando de esta manera ser el sensor más eficiente del mercado (Leica, 2017; Swatantran *et al.*, 2016).

Respecto al vuelo realizado, éste se ejecutó entre el 8 de septiembre y el 16 de noviembre del 2017. Las características técnicas se muestran en la tabla 7:

Tabla 7. Especificaciones técnicas del proyecto. Fuente: Tracasa (2018)

Solape	15%
Precisión	XY: 20 cm Z:15 cm
Pasadas	482
Longitud total de las pasadas de vuelo	16.000 km
Altitud	3.900-6.300 m
Ancho de pasada (media)	2.300 m
Longitud máxima de pasada	110 km
Densidad	14 p/m ²
Velocidad (nudos)	200
Sesiones/Días	40/24

Debido a la orografía de Navarra, donde destaca el acusado relieve de la mitad septentrional, quedaron zonas sin datos debido a las diferencias de altitud de la avioneta y el terreno, por lo que fue necesario repetir algunas pasadas. Como se muestra en la figura 11, en la zona norte fue necesario realizar más pasadas para cubrir estos huecos, por lo que existen zonas en las que la densidad de puntos es superior.




Figura 11. Pasadas realizadas. Fuente: IDENA y elaboración propia

El resultado final fue la publicación de 13.162 bloques en versión LAZ, que cubren un área de 1x1 km. El sistema Geodésico de Referencia utilizado es el ETRS89 UTM huso 30N (EPSG: 25830), con alturas elipsoidales. Los puntos LiDAR llevan asociado las bandas RGBI; esta información fue obtenida de la orto rápida que fue generada a partir de las imágenes adquiridas en el mismo momento de la toma de datos por una cámara de medio formato, en este caso, la cámara RCD30 de Leica. Esta orto tiene diferencias radiométricas y geométricas, por lo que, en algunos casos, la información RGBI puede estar desplazada respecto a los puntos LiDAR. Toda la información se encuentra disponible en la red, bajo la licencia habitual CC BY 3.0 SITNA: ftp://ftp.cartografia.navarra.es/5_LIDAR/.

En la primera cobertura realizada sobre Navarra, los puntos fueron clasificados automáticamente con TerraScan y luego se editó manualmente esa clasificación. En esta segunda cobertura, se descartó la metodología anterior por falta de capacidad del software y los tiempos estimados para el procesamiento de la ingente cantidad de datos; un total de 570.000 millones de puntos distribuidos en 16.000 bloques de procesado. La metodología empleada fue la generación de un único modelo de clasificación mediante técnicas de aprendizaje automático (*Machine Learning*), a partir de la cual se clasificaron todos los puntos.

El aprendizaje automático es un subcampo de la ciencia informática que explora la construcción y el estudio de algoritmos que pueden aprender y realizar predicciones (Dönmez, 2012). Se trata de una de las fases del proceso de descubrimiento de conocimiento (*Knowledge Discovery and Data Mining*, KDD). Para obtener el modelo se utilizan algoritmos de distinta naturaleza; éstos se clasifican en supervisados o no supervisados. El aprendizaje supervisado tiene como objetivo construir un modelo conciso a partir de instancias pre-etiquetadas, con la que luego realizar predicciones sobre instancias futuras (Kotsiantis *et al.*,

2006). En este proceso, se han clasificado de forma manual pequeñas muestras representativas que han servido para entrenar al modelo, que luego ha permitido clasificar todo Navarra de manera automática. A continuación, se explicará brevemente la metodología seguida por Tracasa (2018)²:



Figura 12. Fases seguidas en la clasificación del vuelo de Navarra del 2017

2.2.2.1. Obtención de las muestras

En esta primera fase se definieron las categorías a clasificar, con el fin de entrenar el algoritmo. Las clases informacionales a entrenar fueron las siguientes:

- Suelo (2)
- Vegetación baja (3)
- Vegetación media (4)
- Vegetación alta (5)
- Edificaciones (6)
- Puntos bajos (*Low-points*) (11)

Se obtuvieron un total de 162 muestras de entrenamiento y validación de forma manual a lo largo del territorio navarro y zonas colindantes, que recogen un total de 60 millones de puntos. El 75% de las mismas se dirigieron a entrenar los modelos, las restantes, para validar. Este proceso se realizó mediante el software TerraScan.




Figura 13. Localización de las muestras de entrenamiento y validación. Fuente: Tracasa




Figura 14. Ejemplo de una muestra. En verde, vegetación; suelo, naranja; rojo, edificios; azul, agua y en blanco, sin clasificar. Fuente: Tracasa

² La información ha sido recogida de un documento privado de la empresa, por lo que no se encuentra disponible.

2.2.2.2. Características utilizadas en la clasificación

Para determinar la separabilidad de las categorías participantes, se realizó una extracción de más de 100 características sobre los datos (Tablas 8 y 9), obtenidas de diversas fuentes:

- Características propias de los puntos
- Características obtenidas mediante algoritmos de geometría computacional: librería CGAL (*Computational Geometry Algorithms Library*)
- Características obtenidas mediante la manipulación de nubes de puntos: librería PDAL (*Point Data Abstraction Library*)
- Información vectorial externa

Tabla 8. Características obtenidas por los propios puntos y por la librería PDAL. Fuente: Tracasa

Característica	Descripción
X	Valor en la coordenada X
Y	Valor en la coordenada Y
Z	Valor en la coordenada Z
Intensity	Intensidad
ReturnNumber	Número de retorno
NumberOfReturns	Número de retornos totales
PointSourceId	Número de pasada
Red	Color del punto (en el canal rojo)
Green	Color del punto (en el canal verde)
Blue	Color del punto (en el canal azul)
Infrared	Color del punto (en el canal infrarrojo cercano)
HeightAboveGround	Altura sobre el suelo estimado por PDAL
SmrfClass	Suelo o no estimado por PDAL
CartoC2	Indica si el punto se encuentra sobre una región de suelo: <ul style="list-style-type: none"> – 0 si no lo está – 90 si no lo está, pero con un margen máximo de 2 metros a una zona de suelo – 100 si está dentro de una región de suelo – 110 si está dentro de una región de suelo con un margen mayor a 2 metros
CartoC6	Indica si el punto se encuentra sobre un vector de edificios: <ul style="list-style-type: none"> – 0 si no lo está – 90 si no lo está, pero con un margen máximo de 2 metros a un shape de un edificio – 100 si está dentro de un shape de un edificio – 110 si está dentro de un shape de un edificio con un margen mayor a 2 metros.
Eigenvalue0 0-7	Eigenvalor más pequeño de la matriz de covarianzas basada en el vecindario local
Eigenvalue1 0-7	Eigenvalor medio (segundo más pequeño y más grande) de la matriz de covarianzas basada en el vecindario local
Eigenvalue2 0-7	Eigenvalor mayor de la matriz de covarianzas basada en el vecindario local
Distance to plane 0-7	Distancia del punto a un plano ajustado localmente
Vertical dispersión 0-7	Dispersión vertical de los puntos en un cilindro local alrededor del punto (en Z)
Elevation 0-7	Distancia a una estimación local del suelo
Verticality 0-7	Verticalidad total – orientación de la tangente local al plano
Echo scatter 0-7	Número de retornos – es calculado, no exactamente NumberOfReturns ni ReturnNumber
HDIFF	Distancia del punto al MDT del año 2012

Tabla 9. Características generadas a partir de las obtenidas por las CGAL y las características de cada punto.
 Fuente: Tracasa

Característica		Descripción
NDVI		Índice de Vegetación de Diferencia Normalizada (Normalized Difference Vegetation Index) $NDVI = \frac{\lambda_{IRC} - \lambda_{Red}}{\lambda_{IRC} + \lambda_{Red}}$
Linearity 0-7	Asumiendo que los autovalores son: $\lambda_1 \geq \lambda_2 \geq \lambda_3$ λ_1 : Eigenvalue 2 λ_2 : Eigenvalue 1 λ_3 : Eigenvalue 0	Medida de linealidad del vecindario del punto $L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1}$
Planarity 0-7		Ofrece información sobre la planitud del vecindario $P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1}$
Sphercity 0-7		Ofrece información sobre el tipo de estructura (1D, 2D, 3D) $S_\lambda = \frac{\lambda_3}{\lambda_1}$
Omnivariance 0-7		Ofrece información sobre la relación de los eigenvalores $O_\lambda = \sqrt[3]{\lambda_1 \lambda_2 \lambda_3}$
Anisotropy 0-7		Medida de dependencia de la dirección $A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1}$
Eigentropy 0-7		Medida de desorden de los eigenvalores $E_\lambda = -\sum_{i=1}^3 \lambda_i \ln(\lambda_i)$
ChangeOfCurvature 0-7		Medida de la cantidad de la variación de la superficie $C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}$

Estos cálculos se realizaron a diferentes tamaños de voxel (50 cm; 1, 2, 4, 8, 16 y 32 metros³). El voxel (del inglés *volumetric pixel*) es la unidad cúbica que compone un objeto tridimensional. Por lo tanto, es análogo del píxel en 3 dimensiones, por lo que dentro del mismo se contendrán los puntos LiDAR en un espacio tridimensional (Popescu & Zhao, 2008). Gracias a la definición de su tamaño, podemos marcar el rango de las escalas escogidas. El tamaño definido es por el que se empiezan a calcular las escalas mediante una progresión geométrica.

³ Por esta causa en algunos de los parámetros se especifica 0-7, es decir, se calcula a las distintas escalas propuestas.

Las separabilidades de las distintas características fueron analizadas mediante *Box Plots* (Diagramas de caja). Se trata de una técnica gráfica que nos muestra diferente información estadística descriptiva de los datos. En cada gráfico se muestra cada categoría que interviene en la clasificación, donde se representa el rango, un rectángulo (50% intermedio de los datos, que muestra la distancia entre el primer cuartil y el tercer cuartil, conocida como la distancia intercuartílica) y la mediana de los datos para cada clase (representada por la línea central del rectángulo o caja). En el caso de que existan datos atípicos, también se pueden representar (*outliers*). Si para una característica dada las clases se solapan horizontalmente, estas serán más difíciles de separar o distinguir, por lo que el objetivo es buscar aquellas características que, de forma combinada, hagan separables las clases que intervienen en la clasificación.




Figura 15. Ejemplo de Box Plot y separabilidad de las clases. Fuente: Tracasa

Tras un análisis de los mismos y de los histogramas por clases, se eliminaron varias características no útiles.

2.2.2.3. Obtención del modelo y clasificación de los puntos

La asignación de los puntos a una categoría u otra se realizó en función de las diferentes características que posee cada punto. Esta asignación se realizó comparando varios algoritmos de clasificación:

- K-Nearest Neighbours (Wu *et al.*, 2008)
- Support Vector Machines (Cortes & Vapnik, 1995)
- Decision trees (Wu *et al.*, 2008)
- *Random Forest* (Breiman, 2001)
- Neural Networks (Rumelhart *et al.*, 1986)
- AdaBoost (Dietterich, 2000)
- Naive Bayes (Cochran *et al.*, 2011)
- Logistic Regression (Bishop, 2006)
- Extra Trees (Geurts *et al.*, 2006)
- **XG Boost** (Chen & Guestrin, 2016)

Los algoritmos que mejores resultados obtuvieron fueron Random Forest y XGBoost. El algoritmo XGBoost (*eXtreme Gradient Boosting*) desarrollado por Tianqi Chen, se basa en la técnica Gradient Boosting (Friedman, 1999), obteniendo un conjunto de árboles de decisión. Este último fue el elegido ya que resultó más preciso, rápido y eficiente.

A continuación, se muestra un listado de parámetros que proporcionaron un resultado óptimo en la clasificación.

A. Tamaño del conjunto de datos

En un primer momento se trabajó con el 100% de los datos del conjunto del entrenamiento. Debido a su gran coste computacional, se procedió a realizar pruebas con un submuestreo de los puntos desde el 10% hasta el 100% con pasos sucesivos del 10%. Tras realizar las pruebas, se mostró que utilizando únicamente el 10% se obtuvieron resultados casi idénticos, con mínimas variaciones, que con el 100% de los datos.

B. Ajuste de parámetros propios de XGBoost

Los parámetros a aplicar en el algoritmo se obtuvieron haciendo uso del conjunto de validación y de diferentes medidas de precisión. Estos se muestran en la tabla 10:

Tabla 10. Ajuste de los parámetros del algoritmo utilizado. Fuente: Tracasa

Parámetro	Valor
N estimators (número de árboles)	100
Learning rate	0.01
Max depth	6
Objective	Softmax
Min child weight	4
Gamma	0.2
Subsample	0.8
Colsample bytree	0.8
Reg alpha	0.0003
Use class weights	0

C. Tamaño de voxel

Inicialmente se trabajó con un voxel de tamaño variable para cada muestra, determinado automáticamente por las CGAL. En este caso, resultó más adecuado trabajar con un mismo tamaño de voxel para todas las muestras, ya que se pretende entrenar un modelo válido de forma global.

El tamaño del voxel se utiliza para agilizar el cálculo de los vecinos de un punto, sustituyendo todos los puntos que caen en un mismo voxel por su punto medio. Por lo tanto, cuanto mayor es el tamaño del voxel, más ágil será el cálculo, reduciendo considerablemente el coste computacional; a cambio de reducir su precisión. Cuanto menor es el tamaño, en cambio, los cálculos serán más precisos, a cambio de un mayor coste computacional.

Una vez definido el voxel (en este caso 25 cm), se decidieron el número total de escalas superiores a las que trabajo. En este caso, se realizaron pruebas con un máximo de 8 escalas, por lo que se obtuvieron los tamaños de voxel de 25 cm, 50 cm, 1 m, 2 m, 4 m, 8 m, 16 m y 32 m.

Tras obtener distintas medidas sobre los modelos entrenados a diferentes tamaños de voxel, se comprobó que menores tamaños de voxel funcionaban mejor. En cuanto al número de escalas, las diferencias de precisión eran muy pequeñas. Por lo tanto, los experimentos finales se realizaron a 6 escalas: 25 cm, 50 cm, 1 m, 2 m, 4 m y 8 m.

D. Modelo en dos fases

Con el fin de obtener una clasificación más precisa, se propuso un proceso de clasificación en dos fases, donde en la primera se creó un modelo binario en el que se predicen los puntos de la clase suelo y los de no suelo, y en la segunda se clasifican en las clases restantes los puntos no pertenecientes al suelo.

2.2.2.4. Validación

Una vez entrenado el algoritmo y clasificados los datos, se obtuvieron diferentes métricas de rendimiento basadas en matrices de confusión, como *Precision*, *Recall* y *F-measure*.

Los resultados proporcionados por estas medidas de rendimiento son objetivos, estandarizados y dan una idea general del grado de acierto del clasificador. Sin embargo, no tienen en cuenta otros aspectos importantes como la gravedad del error. Es decir, consideran todos los errores por igual y no permiten realizar una gradación sobre la gravedad de los errores cometidos.

Hasta la fecha esta limitación de las medidas de rendimiento se ha compensado con la realización de valoraciones visuales, ya que permiten descubrir errores puntuales que aun siendo pocos (es decir, teniendo medidas de rendimiento adecuadas) pueden ser importantes y tener consecuencias graves en los productos derivados obtenidos a partir de esa clasificación.

Por lo tanto, existen tres cuestiones importantes que las medidas de rendimiento estándar no son capaces de detectar.

- Error en la asignación de la clase según la altura a la que se posicione el punto sobre el suelo
- Distinto peso del error según las clases que confunda.
- Vecindad/aislamiento del punto erróneo sobre otros puntos bien clasificados o erróneos de la misma clase.

Por esta causa, el propósito de este TFM es investigar otro tipo de medidas que reflejen las observaciones visuales, con el fin de evaluar las clasificaciones generadas de manera más eficiente.

2.3. Aportaciones metodológicas

2.3.1. Fase I: Validador

El primer objetivo de este trabajo consiste en generar un validador de puntos LiDAR que evalúe los diferentes errores de clasificación con la propia información obtenida en el vuelo. Esto resulta importante ya que, de esta manera, esta herramienta puede ser utilizada para cualquier vuelo LiDAR independientemente de que exista información externa que nos ayude a evaluar esos puntos (por ejemplo, vectores que representen la localización de los edificios). En él, los puntos erróneos serán evaluados, aplicándoles unos valores que calculan la gravedad del error en base a diferentes medidas. De esta manera, cada punto será ponderado evaluando la gravedad del error en cada caso.

La metodología seguida en la evaluación se basa en comparar punto contra punto. Para ello, es necesario que un mismo fichero que contiene los puntos LiDAR esté clasificado perfectamente (conjunto de datos de validación o test), por lo que debe de existir un trabajo

previo de clasificación detallada del bloque que se desea comparar. En el caso de querer evaluar un modelo que ha sido utilizado en una gran cantidad de bloques (por ejemplo, clasificación realizada sobre un lote entero) se deberían clasificar algunos de los bloques manualmente y realizar la comparación sobre los mismos, y con ello, obtener una idea general del funcionamiento del modelo. En este caso, deberían escogerse varios bloques representativos, en los que encontremos diferentes tipologías (urbano denso, edificaciones aisladas, bosques, plantaciones, etc.).

El validador, además de ofrecernos información general del modelo, nos ofrece información del error de cada punto, pudiendo observar la gravedad de cada uno de ellos. Es necesario recalcar que únicamente se tienen en cuenta las siguientes clases:

- Suelo (2)
- Vegetación baja (3): de 0 a 0.3 metros
- Vegetación media (4): de 0.3 a 3 metros, asimilable a matorral y estrato arbustivo.
- Vegetación alta (5): más de 3 metros, asimilable al estrato arbóreo.
- Edificios (6)
- Puntos bajos (11): Puntos situados bajo el suelo. Conocidos como *Low Points*.
- Artefactos sobre el suelo (13): Clase que aglutina diferentes objetos que podemos encontrar sobre la superficie. En este caso, la mayoría de puntos de esta clase representan automóviles. Esta clase ha sido creada expresamente para este trabajo.

A pesar que la clase 11 y 13, según la ASPRS corresponden a las clases de carretera y tendido eléctrico, se ha decidido utilizar esta numeración de acuerdo al PTC⁴ utilizado en la empresa. Además, lo dictado por la ASPRS no es obligatorio, por lo que estos valores pueden ser utilizados como quiera el usuario final.

Por tanto, el objetivo planteado es el de desarrollar un validador que dado un conjunto de puntos LiDAR correspondientes a una zona y dos clasificaciones, una realizada manualmente (de referencia) y otra automática (el modelo obtenido), nos indique cómo de correcta es la segunda respecto a la de referencia comparando los dos bloques punto por punto. Este validador funciona de la siguiente manera:

1. Para cada punto erróneo, calculamos diferentes medidas que nos van a ayudar a ponderar esa gravedad (Apartado 2.3.1.1).
2. Convertimos esas medidas a valores de gravedad mediante funciones según la lógica del problema (Apartado 2.3.1.2).
3. Se obtiene para cada punto un valor de gravedad. A partir de este valor de error total y los parámetros calculados, se obtienen diferentes estadísticas (Apartado 2.3.1.3).

2.3.1.1. Medidas

Tras revisar las diferentes posibilidades, teniendo en cuenta que únicamente puede ser utilizada la información propia de la nube de puntos o aquella que pueda ser extraída a partir de la misma mediante cálculos, se propusieron diferentes medidas (Tabla 11). Para ello, se generó un programa (*las-discrepancy2csv*, figura 16) que obtuviese dicha información para cada punto de manera automática:

⁴ Se trata de un tipo de fichero que guarda información relativa a los valores posibles de la clasificación.

Tabla 11. Diferentes medidas a calcular a partir de los propios datos

Nombre	Descripción
RasterZDiff	Distancia del punto erróneo sobre el MDT. El MDT es generado a partir de los puntos de la clase suelo del bloque de referencia.
ClassFile1	Clase del punto erróneo (información obtenida a partir del bloque que se desea validar)
ClassFile2	Clase del punto bien clasificado (información obtenida a partir del bloque de referencia)
NeighborCount	Número de puntos vecinos dentro del voxel.
NeighborClassFile1	Se obtiene la clase mayoritaria de los vecinos del punto erróneo sobre el bloque modelo.
NeighborClassFile2	Se obtiene la clase mayoritaria de los vecinos del punto erróneo sobre el bloque de referencia.
NeighborDistFile1	Distancia entre cualquier punto erróneo, teniendo en cuenta su clase, al más cercano de la misma clase, pero clasificado correctamente.
NeighborDistFile2	Distancia entre cualquier punto erróneo, teniendo en cuenta su clase, al más cercano de la misma clase que también haya sido mal clasificado.

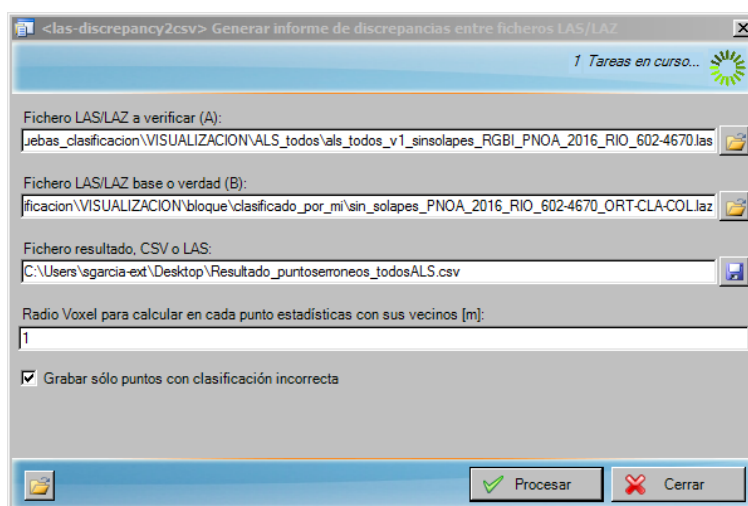


Figura 16. Programa las-discrepancy2csv

2.3.1.2. Ponderación de los errores

Todos los parámetros a calcular poseen un resultado entre 0 y 100 puntos o 150. El cálculo se realiza a partir de los valores obtenidos en las medidas que encontramos en la tabla 11, que se traducen en valores de error a partir de una matriz de costes o de una función que representa el error en base a la distancia.

Para cada punto obtenemos los siguientes 4 parámetros, obteniendo de esta manera un máximo de 400 puntos:

- **ErrorClase:** Comparación entre la clase obtenida en el modelo (ClassFile1) y en el bloque perfectamente clasificado (ClassFile2). El valor de error se obtiene a partir de una matriz de costes (Tabla 12). El coste varía dependiendo en las clases que se confunde; por ejemplo, el error es menos grave si se confunde entre suelo y baja vegetación que suelo con vegetación alta.

Tabla 12. Matriz de costes: Diferencia de clases

		Clase correcta (ClassFile2)						
		2	3	4	5	6	11	13
Clase errónea (ClassFile1)	2		25	40	80	100	60	100
	3	10		25	40	80	65	90
	4	50	25		25	55	70	25
	5	100	60	25		35	75	25
	6	100	80	55	35		80	20
	11	80	85	90	95	100		100
	13	100	90	25	25	20	100	

- **DistMDT:** El valor de error varía respecto a la diferencia de altura del punto sobre el MDT (RasterZdiff). En este caso, se tiene en cuenta la clase incorrecta del punto (ClassFile1) y se aplican distintas funciones según la clase correspondiente. Por lo tanto, existen tantas funciones como clases, que han sido generadas teniendo en cuenta sobre qué rangos de altura se encuentran esas clases sobre el MDT; por ejemplo, un punto clasificado como suelo erróneamente situado a un metro sobre el MDT, el valor de error será más alto que si estuviera a 25 cm.

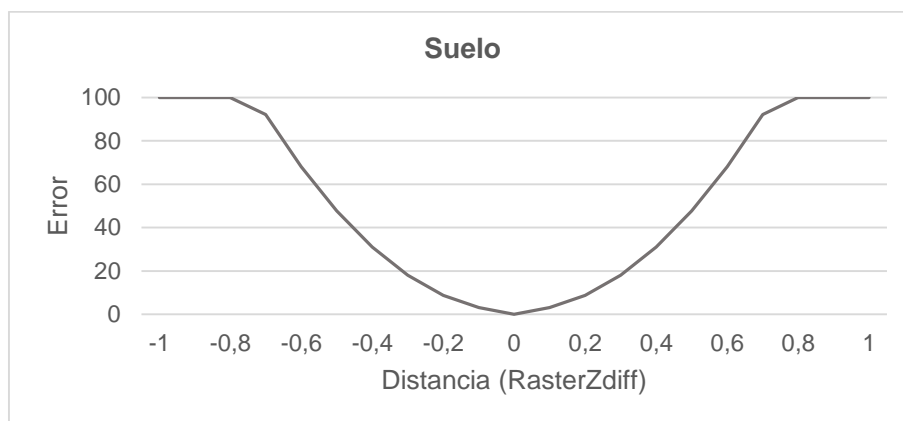


Figura 17. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase suelo




Figura 18. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Vegetación baja

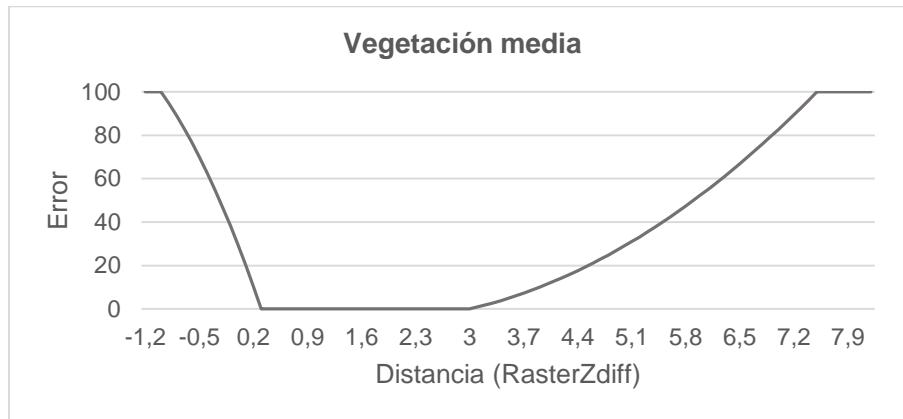


Figura 19. Gráfica de la función del parámetro *DistMDT* para el punto erróneo de la clase *Vegetación media*




Figura 20. Gráfica de la función del parámetro *DistMDT* para el punto erróneo de la clase *Vegetación alta*

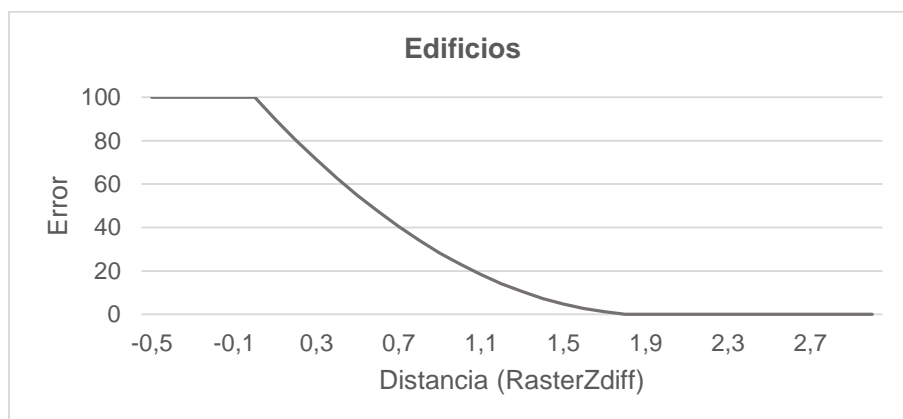


Figura 21. Gráfica de la función del parámetro *DistMDT* para el punto erróneo de la clase *Edificios*

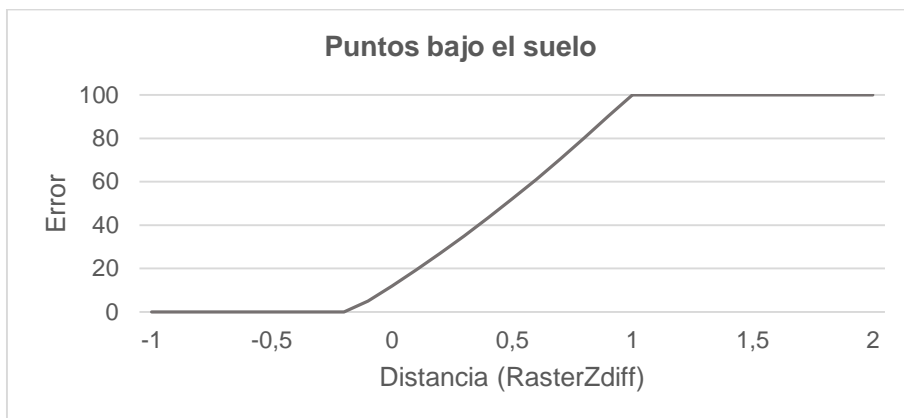


Figura 22. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Puntos bajo el suelo

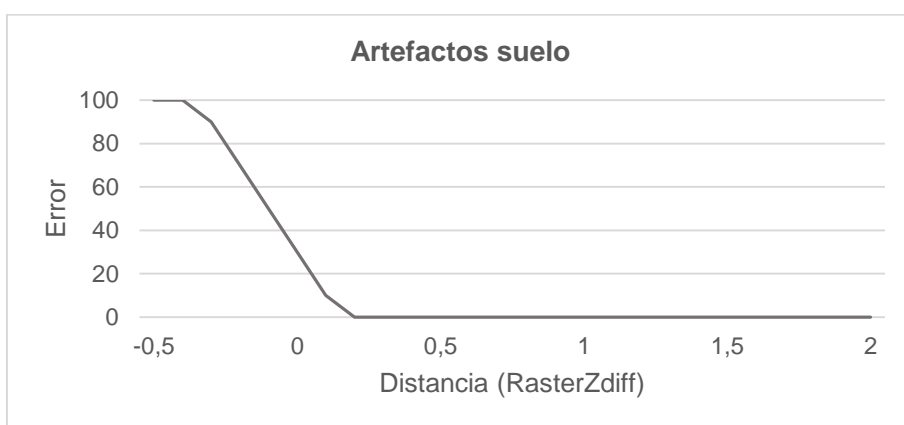


Figura 23. Gráfica de la función del parámetro DistMDT para el punto erróneo de la clase Artefactos sobre el suelo

- **DistFile1:** El valor de error varía según la distancia entre cualquier punto erróneo, teniendo en cuenta su clase errónea, con otro punto de esa misma clase, pero clasificado correctamente (NeighborDistFile1). Por lo tanto, según la función, cuanto más aislado se encuentre un punto erróneo sobre uno de la misma clase bien clasificado, el error será mayor. El valor de error se obtiene mediante la siguiente función:

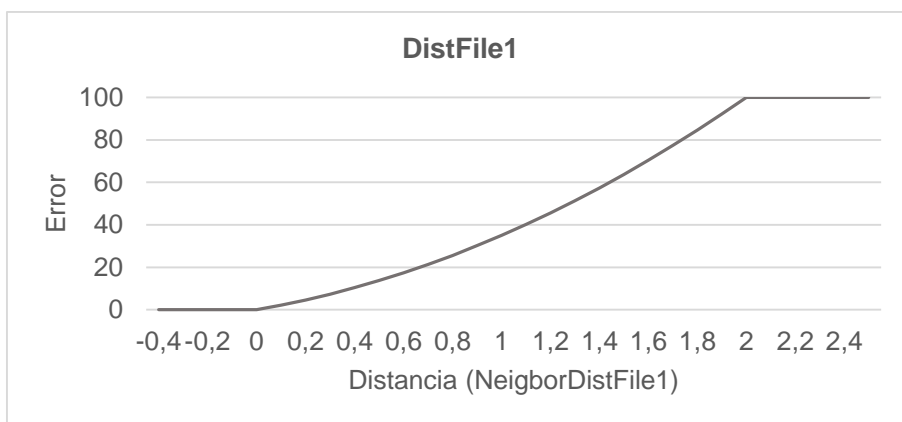


Figura 24. Gráfica de la función del parámetro DistFile1

- **DistFile2:** El valor de error será mayor ahí donde exista una agrupación de puntos erróneos de esa misma clase, ya que se utiliza la distancia existente entre cualquier punto erróneo, teniendo en cuenta su clase errónea, con otro punto de esa misma clase pero que haya sido clasificado también erróneamente (NeighborDistFile2). El valor de error se otorga mediante la siguiente función:

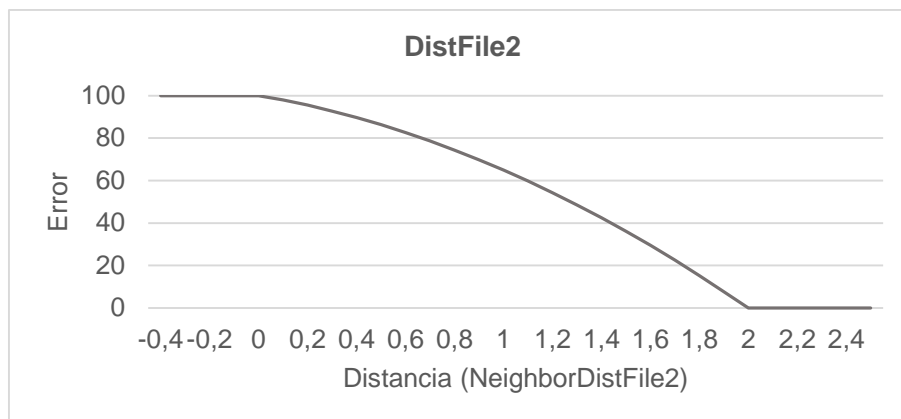


Figura 25. Gráfica de la función del parámetro DistFile2

En la validación también se tiene en cuenta la vecindad de cada punto. Para ello, se ha de ofrecer un tamaño de voxel para su cálculo al ejecutar el programa. En el caso de que existan vecinos dentro del voxel (si NeighbourCount es igual a 1 o mayor), se calculan los siguientes parámetros, que pueden obtener una puntuación entre 0 y 100. Al tratarse de 3 parámetros, se pueden obtener un máximo de 300 puntos:

- **Vecindad ClassFile1:** Se compara la clase del punto erróneo (ClassFile1) con la vecindad de ese punto en la clasificación del modelo (NeighbourClassFile1) a través de una matriz de costes. El objetivo de este parámetro es penalizar aquellos puntos erróneos aislados, que se encuentren entre otros puntos de otras clases. Además, el error varía según la comparación entre ese punto erróneo y la clase mayoritaria.

Tabla 13. Matriz de costes: Clase mayoritaria de los vecinos en la clasificación del modelo

		Clase mayoritaria de los vecinos en la clasificación del modelo						
		2	3	4	5	6	11	13
Clase del punto erróneo	2		2	40	80	90	2	90
	3	2		25	40	80	65	70
	4	50	25		25	60	70	30
	5	100	60	25		50	75	30
	6	100	80	60	50		80	25
	11	2	85	90	95	100		100
	13	90	70	30	30	25	100	

- **Vecindad ClassFile2:** Se compara la clase del punto erróneo (ClassFile1) con la mayoritaria del bloque bien clasificado (NeighbourClassFile2) a través de una matriz de costes. Este parámetro sigue la misma lógica que Vecindad ClassFile1, pero los

errores asignados son mayores, ya que las vecindades se obtienen sobre el bloque de referencia y no desde el modelo:

Tabla 14. Matriz de costes: Clase mayoritaria de los vecinos en la clasificación de referencia

		Clase mayoritaria de los vecinos en la clasificación de referencia						
		2	3	4	5	6	11	13
Clase del punto erróneo	2		5	60	100	100	5	95
	3	5		45	60	100	70	90
	4	70	45		45	90	85	45
	5	100	80	45		70	100	45
	6	100	100	75	70		100	35
	11	5	70	85	100	100		100
	13	95	90	45	45	35	100	

- **Combinación vecindad:** El objetivo de este parámetro es aumentar el error en el caso de que la vecindad varíe entre el modelo y el bloque de referencia; si la clase mayoritaria es la misma en los dos, el valor de error es de 0. En el caso de que la clase mayoritaria cambie, el error variará según las clases que se comparen. El valor es obtenido a partir de una matriz de costes:

Tabla 15. Matriz de costes: Diferencia de clases de las diferentes vecindades

		Clase mayoritaria de los vecinos de la clasificación de referencia (NeighbourClassFile2)						
		2	3	4	5	6	11	13
Clase mayoritaria de los vecinos del modelo	2		5	70	100	100	5	100
	3	5		20	60	100	95	95
	4	80	20		20	100	95	50
	5	100	90	20		80	100	50
	6	100	100	80	80		100	40
	11	5	95	95	100	100		100
	13	100	95	50	50	40	100	

En el caso de que no exista ningún punto vecino dentro del voxel, es decir, si el valor de NeighbourCount es igual a 0, se opta por utilizar otros dos parámetros ya calculados para todos los puntos de gran importancia (ErrorClase y DistMDT). El valor obtenido en esos dos parámetros ha de multiplicarse por 1,5, de esta manera, el punto erróneo podrá obtener una puntuación entre 0 y 150 en cada uno de ellos, logrando equipararse a los 300 puntos que también pueden obtenerse en el caso de que el punto erróneo tenga vecinos. Estos dos nuevos parámetros se llaman ErrorClase_2 y DistMDT_2.

Para concluir, en la figura 26 se muestra un esquema de los parámetros calculados:

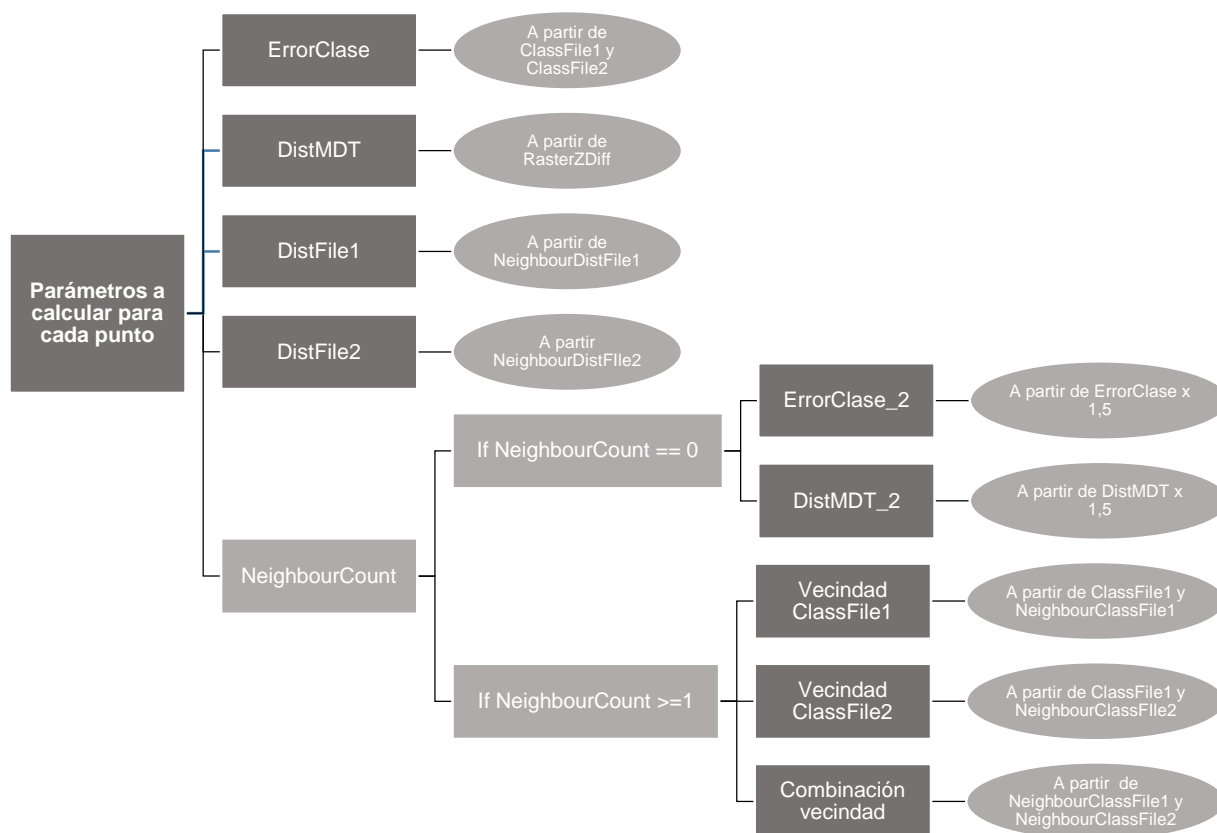


Figura 26. Esquema de los parámetros calculados para cada punto

2.3.1.3. Resultados

A partir de la obtención de los puntos erróneos y los parámetros establecidos en el punto 2.2.1, es posible obtener diferentes resultados que además de dar una idea general del grado de acierto del clasificador, son capaces de realizar una gradación sobre la gravedad de los errores cometidos.

En primer lugar, se obtienen diferentes medidas básicas:

- **Número total de puntos del bloque:** N
- **Número total de puntos erróneos del bloque:** N_e
- **% de puntos erróneos sobre el total:** $\frac{N_e \cdot 100}{N}$
- **Puntos erróneos por clases:** El número de puntos erróneos se desglosan en las diferentes clases que se tienen en cuenta. De esta forma, se obtiene una idea general del número de errores, tanto sobre el total de puntos de esa misma clase a la que pertenece el punto erróneo y sobre el total de puntos erróneos (Tabla 16).

Tabla 16. Medidas básicas

Clase	Errores	Nº total de puntos de la clase	% error sobre el total de puntos de esa misma clase	% sobre el total de puntos erróneos
2	e_2	n_2	$\frac{e_2 * 100}{n_2}$	$\frac{e_2 * 100}{N}$
3	e_3	n_3	$\frac{e_3 * 100}{n_3}$	$\frac{e_3 * 100}{N}$
4	e_4	n_4	$\frac{e_4 * 100}{n_4}$	$\frac{e_4 * 100}{N}$
5	e_5	n_5	$\frac{e_5 * 100}{n_5}$	$\frac{e_5 * 100}{N}$
6	e_6	n_6	$\frac{e_6 * 100}{n_6}$	$\frac{e_6 * 100}{N}$
11	e_{11}	n_{11}	$\frac{e_{11} * 100}{n_{11}}$	$\frac{e_{11} * 100}{N}$
13	e_{13}	n_{13}	$\frac{e_{13} * 100}{n_{13}}$	$\frac{e_{13} * 100}{N}$
Total	N_e	N	100	100

En segundo lugar, se obtienen resultados respecto al tipo de error cometido. Como se ha descrito en el punto 2.2.1, los distintos parámetros pueden obtener valores entre 0 y 100 o 150, por lo tanto, cada punto erróneo puede obtener hasta un total de 700 puntos, con el fin de clasificarlo por rangos respecto a la puntuación obtenida (Tabla 17):

Tabla 17. Tipo de error respecto a la puntuación obtenida

Puntuación	Tipo de error
<= 150	No problema
151-350	Leve
351-500	Algo grave
501-600	Grave
601-700	Muy grave

A partir del rango establecido, se establecen diferentes medidas:

- **Por tipo de error sobre el total de puntos del bloque y el total de erróneos:**

Tabla 18. Medidas por tipo de error

Tipo error	Nº de puntos	% sobre el total de puntos	% sobre el total de errores
No problema	$e_{no\ problema}$	$\frac{e_{no\ problema} * 100}{N}$	$\frac{e_{no\ problema} * 100}{N_e}$
Leve	e_{leve}	$\frac{e_{leve} * 100}{N}$	$\frac{e_{leve} * 100}{N_e}$
Algo grave	$e_{algo\ grave}$	$\frac{e_{algo\ grave} * 100}{N}$	$\frac{e_{algo\ grave} * 100}{N_e}$
Grave	e_{grave}	$\frac{e_{grave} * 100}{N}$	$\frac{e_{grave} * 100}{N_e}$
Muy grave	$e_{muy\ grave}$	$\frac{e_{muy\ grave} * 100}{N}$	$\frac{e_{muy\ grave} * 100}{N_e}$
Total	N_e	100	100

– Tipos de fallo por clase:

Tabla 19. Medidas de tipos de error por clase (totales)

Clases	No problema	Leve	Algo grave	Grave	Muy grave	Total
2	$e_{no\ problema,2}$	$e_{leve,2}$	$e_{algo\ grave,2}$	$e_{grave,2}$	$e_{muy\ grave,2}$	$N_{e,2}$
3	$e_{no\ problema,3}$	$e_{leve,3}$	$e_{algo\ grave,3}$	$e_{grave,3}$	$e_{muy\ grave,3}$	$N_{e,3}$
4	$e_{no\ problema,4}$	$e_{leve,4}$	$e_{algo\ grave,4}$	$e_{grave,4}$	$e_{muy\ grave,4}$	$N_{e,4}$
5	$e_{no\ problema,5}$	$e_{leve,5}$	$e_{algo\ grave,5}$	$e_{grave,5}$	$e_{muy\ grave,5}$	$N_{e,5}$
6	$e_{no\ problema,6}$	$e_{leve,6}$	$e_{algo\ grave,6}$	$e_{grave,6}$	$e_{muy\ grave,6}$	$N_{e,6}$
11	$e_{no\ problema,11}$	$e_{leve,11}$	$e_{algo\ grave,11}$	$e_{grave,11}$	$e_{muy\ grave,11}$	$N_{e,11}$
13	$e_{no\ problema,13}$	$e_{leve,13}$	$e_{algo\ grave,13}$	$e_{grave,13}$	$e_{muy\ grave,13}$	$N_{e,13}$
Total	$N_{no\ problema}$	N_{leve}	$N_{algo\ grave}$	N_{grave}	$N_{muy\ grave}$	

En relación a la tabla 19:

Tabla 20. Medidas de tipos de error por clase (en porcentajes)

Clases	No problema	Leve	Algo grave	Grave	Muy grave	Total	Clase mayoritaria por tipo de error
2	$\frac{e_{no\ problema,2} * 100}{N_{e,2}}$	$\frac{e_{leve,2} * 100}{N_{e,2}}$	$\frac{e_{algo\ grave,2} * 100}{N_{e,2}}$	$\frac{e_{grave,2} * 100}{N_{e,2}}$	$\frac{e_{muy\ grave,2} * 100}{N_{e,2}}$	100	Se especifica la clase que obtiene el mayor porcentaje en cada tipo de error
3	$\frac{e_{no\ problema,3} * 100}{N_{e,3}}$	$\frac{e_{leve,3} * 100}{N_{e,3}}$	$\frac{e_{algo\ grave,3} * 100}{N_{e,3}}$	$\frac{e_{grave,3} * 100}{N_{e,3}}$	$\frac{e_{muy\ grave,3} * 100}{N_{e,3}}$	100	
4	$\frac{e_{no\ problema,4} * 100}{N_{e,4}}$	$\frac{e_{leve,4} * 100}{N_{e,4}}$	$\frac{e_{algo\ grave,4} * 100}{N_{e,4}}$	$\frac{e_{grave,4} * 100}{N_{e,4}}$	$\frac{e_{muy\ grave,4} * 100}{N_{e,4}}$	100	
5	$\frac{e_{no\ problema,5} * 100}{N_{e,5}}$	$\frac{e_{leve,5} * 100}{N_{e,5}}$	$\frac{e_{algo\ grave,5} * 100}{N_{e,5}}$	$\frac{e_{grave,5} * 100}{N_{e,5}}$	$\frac{e_{muy\ grave,5} * 100}{N_{e,5}}$	100	
6	$\frac{e_{no\ problema,6} * 100}{N_{e,6}}$	$\frac{e_{leve,6} * 100}{N_{e,6}}$	$\frac{e_{algo\ grave,6} * 100}{N_{e,6}}$	$\frac{e_{grave,6} * 100}{N_{e,6}}$	$\frac{e_{muy\ grave,6} * 100}{N_{e,6}}$	100	
11	$\frac{e_{no\ problema,11} * 100}{N_{e,11}}$	$\frac{e_{leve,11} * 100}{N_{e,11}}$	$\frac{e_{algo\ grave,11} * 100}{N_{e,11}}$	$\frac{e_{grave,11} * 100}{N_{e,11}}$	$\frac{e_{muy\ grave,11} * 100}{N_{e,11}}$	100	
13	$\frac{e_{no\ problema,13} * 100}{N_{e,13}}$	$\frac{e_{leve,13} * 100}{N_{e,13}}$	$\frac{e_{algo\ grave,13} * 100}{N_{e,13}}$	$\frac{e_{grave,13} * 100}{N_{e,13}}$	$\frac{e_{muy\ grave,13} * 100}{N_{e,13}}$	100	

En tercer lugar, se obtiene una matriz de confusión, que muestra los posibles conflictos entre el bloque a verificar y el de referencia; en las filas se muestran las categorías de referencia, en las columnas, en cambio, las categorías predichas. En la diagonal encontramos los puntos en los que se produce acuerdo entre el bloque clasificado y la información de referencia, en las zonas marginales se encuentran los puntos erróneamente clasificados, asignados a otras categorías a las que no pertenecen en la realidad (Tabla 21).

Tabla 21. Matriz de confusión por clases

		Datos predichos							Total
		2	3	4	5	6	11	13	
Datos de referencia	2	x_{22}							x_{2+}
	3		x_{33}						x_{3+}
	4			x_{44}					x_{4+}
	5				x_{55}				x_{5+}
	6					x_{66}			x_{6+}
	11						x_{1111}		x_{11+}
	13							x_{1313}	x_{13+}
	Total	x_{+2}	x_{+3}	x_{+4}	x_{+5}	x_{+6}	x_{+11}	x_{+13}	

A partir de la matriz, se calculan las siguientes estadísticas (Tabla 22):

Tabla 22. Estadísticas obtenidas a partir de la matriz de confusión. Fuente: Congalton & Green (2008)

Nombre	Descripción	Fórmula
Fiabilidad global	Comentadas en la tabla 5	
Estadístico Kappa		
Error omisión	Porcentaje de puntos que perteneciendo a una clase i no fueron incluidos en ella. Es calculado para cada clase.	$EO_i = 1 - \frac{X_{ii}}{X_{+i}}$
Error comisión	Porcentaje de puntos que se incluyeron en una categoría i , perteneciendo realmente a otra. Es calculado para cada clase.	$EC_i = 1 - \frac{X_{ii}}{X_{+i}}$

Junto a los resultados obtenidos en las tablas 21 y 22, se ofrecen los siguientes resultados:

Tabla 23. Ejemplo de tabla para la clase 2

Clase modelo	Clase referencia	Número de puntos	% total de los puntos erróneos de esa misma clase
2	3	$c_{3,2}$	$\frac{c_{3,2} * 100}{n_{e,2}}$
2	4	$c_{4,2}$	$\frac{c_{4,2} * 100}{n_{e,2}}$
2	5	$c_{5,2}$	$\frac{c_{5,2} * 100}{n_{e,2}}$
2	6	$c_{6,2}$	$\frac{c_{6,2} * 100}{n_{e,2}}$
2	11	$c_{11,2}$	$\frac{c_{11,2} * 100}{n_{e,2}}$
2	13	$c_{13,2}$	$\frac{c_{13,2} * 100}{n_{e,2}}$
		$n_{e,2}$	100

En cuarto y último lugar, se ofrece una tabla donde aparece el número de errores groseros (Tabla 24). Estos se calculan a partir de su valor en RasterZdiff; si su valor es superior o inferior (establecido por clases para el punto erróneo) sobre el MDT, se considerará un error grosero:

Tabla 24. Errores groseros

Clase errónea	Superior a la altura del MDT	Inferior a la altura del MDT	% de errores groseros en cada clase respecto a los puntos erróneos de esa misma clase
2	$c_{2,egA} = c_2 \geq 1,5$	$c_{2,egB} = c_2 \leq -1,5$	$\frac{(c_{2,egA} + c_{2,egB}) * 100}{n_{e,2}}$
3	$c_{3,egA} = c_3 \geq 1,5$	$c_{3,egB} = c_3 \leq -1$	$\frac{(c_{3,egA} + c_{3,egB}) * 100}{n_{e,3}}$
4	$c_{4,egA} = c_4 \geq 7,5$	$c_{4,egB} = c_4 \leq -0,1$	$\frac{(c_{4,egA} + c_{4,egB}) * 100}{n_{4,2}}$
5	-	$c_{5,egB} = c_5 \leq -0,1$	$\frac{c_{5,egB} * 100}{n_{e,5}}$
6	-	$c_{6,egB} = c_6 \leq -0,1$	$\frac{c_{6,egB} * 100}{n_{e,6}}$
11	$c_{5,egA} = c_{11} \geq 1$	-	$\frac{c_{11,egB} * 100}{n_{e,11}}$
13	-	$c_{13,egB} = c_{13} \leq -0,1$	$\frac{c_{13,egB} * 100}{n_{e,13}}$
	Total de errores groseros	% sobre el total de puntos erróneos	
Total errores groseros	N_{eg}	$\frac{N_{eg} * 100}{N_e}$	

En resumen, en la siguiente figura (27), se muestra un esquema de los resultados obtenidos gracias al validador:

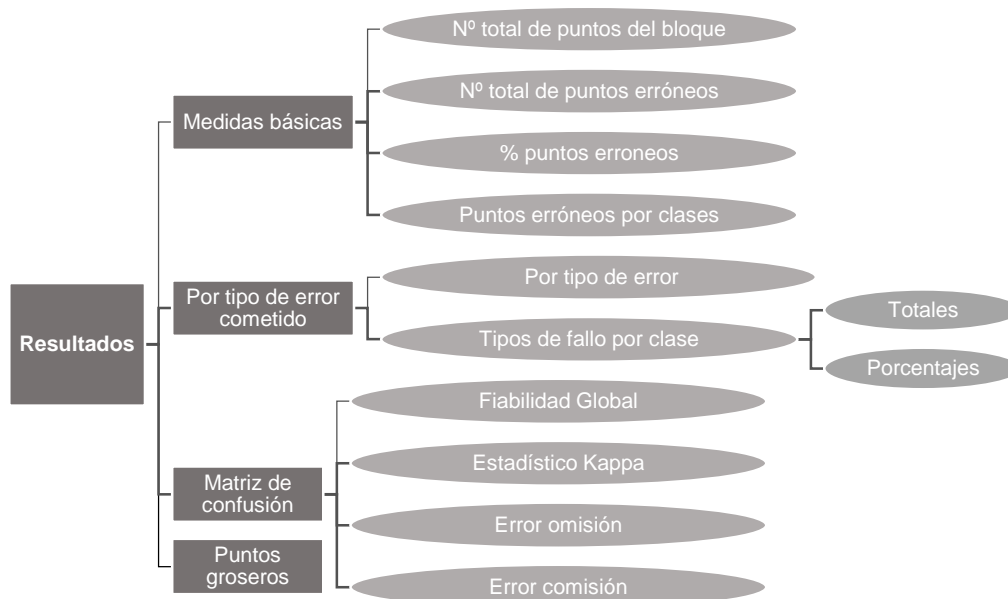


Figura 27. Resumen de los resultados obtenidos

2.3.2. Fase II: Clasificación

En esta segunda fase del proyecto, se han utilizado datos de diversas fuentes, que corresponden a vuelos LiDAR realizados con otros sensores y densidades de diferentes coberturas del PNOA, con el fin de clasificarlos adaptando el algoritmo implementado para los datos del vuelo realizado en 2017 sobre Navarra con el sensor SPL100 (Algoritmo descrito en el apartado 2.2.2). Los resultados obtenidos se evalúan con la herramienta propuesta en la fase anterior.

2.3.2.1. Búsqueda de datos

Con el fin de realizar las diferentes pruebas, se han escogido los siguientes sensores:

1. ALS80

Dentro de la familia de los sensores ALS se ha escogido el sensor ALS80 por una razón relacionada con la densidad disponible de los datos; de todos los sensores Leica, parecidos técnicamente entre sí, se disponen datos a 0.5, 1 y 2 puntos por m² con este sensor.

El sensor, de la empresa Leica Geosystems, es un sistema diseñado para la adquisición de datos de la superficie terrestre disponible para plataformas aéreas, que trabaja a alturas de vuelo de hasta 5000 metros y a la longitud de onda del infrarrojo cercano. Los pulsos son lanzados mediante el mecanismo del espejo oscilante, por lo que se obtiene un patrón de zig-zag en los datos. Existen tres variantes del mismo sensor (Leica, n.d.):

- Leica ALS80-CM: Diseñado para aplicaciones urbanas y vuelos a baja altura.
- Leica ALS80-HP: Diseñado para mapeo en general y vuelos a alturas habituales.
- Leica ALS80-HA: Variante diseñada para volar a gran altura.

2. RIEGL MLS-Q680i y RIEGL MLS-Q780

Con el fin de trabajar con otro tipo de sensores que no fuesen de la familia Leica, se han escogido los sensores Q-680 y Q-780 de la empresa Riegl. En el marco del PNOA, se han utilizado estos dos sensores en el mismo lugar (Valencia) y con una misma densidad (1 p/m²).

El sensor MLS-680i ha sido diseñado para su utilización en aeronaves, que es capaz de obtener información a alturas superiores de 5000 metros y que trabaja en la longitud de onda del infrarrojo cercano. Se trata de un sistema de onda continua que utiliza el mecanismo de prisma rotatorio, por lo que se obtiene un patrón de líneas paralelas. Respecto a la cantidad de puntos que puede obtener por segundo, la cifra puede alcanzar hasta las 220000 mediciones (Riegl, 2012).

En el caso del sensor VQ-780i, éste se trata de una mejora respecto al anterior, ya que básicamente contiene las mismas características. La única diferencia se encuentra en la cantidad de puntos que adquiere, ya que este sensor es capaz de obtener 660000 mediciones por segundo (Riegl, 2019).

2.3.2.2. Unión de la información infrarroja

Los bloques disponibles para su descarga en el CNIG se encuentran duplicados; esto se debe a que se ofrece la información de los canales RGB e IRC por separado (Figura 28).

Nombre	Formato	Tamaño (MB)	Localizar	Descargar	+ -
Coloreado (IRC) 2015 - PNOA-2015-GAL-W-558-4802-ORT-CLA-CIR.LAZ	LAZ	24.53			Añadir
Coloreado (RGB) 2015 - PNOA-2015-GAL-W-558-4802-ORT-CLA-COL.LAZ	LAZ	25.16			Añadir

Figura 28. Ejemplo de la duplicación de información. Fuente: CNIG (n.d.)

Esto supone un problema, ya que en la metodología seguida por Tracasa los canales RGBI son utilizados como características para la clasificación (Tabla 8). Por lo tanto, resulta necesario disponer de toda esa información en el mismo fichero. Para ello, se desarrolló un programa que uniese dicha información (*las-join-rgb nir-ignspain*, figura 29).

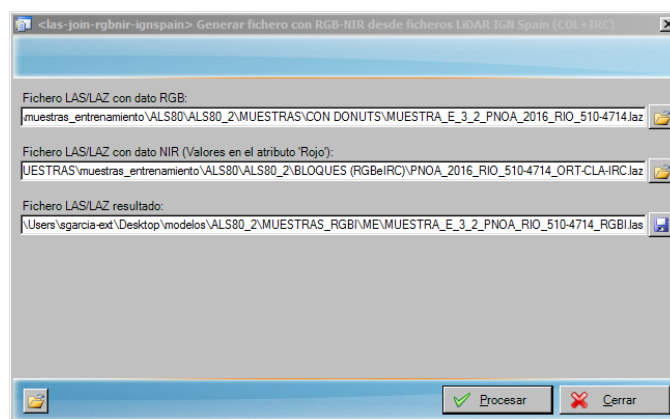


Figura 29. Programa *las-join-rgb nir-ignspain*

Como se puede observar en la figura 29, la información a incluir es el fichero donde se guarda la información RGB y la que se incluye es el infrarrojo. En este caso, el fichero que contiene la información NIR es dependiente del RGB, es decir, solo se incluye la información NIR en el caso de que exista un punto idéntico (mismas coordenadas X, Y y Z) en el fichero con la información RGB. En la tabla 25 se muestra la organización de las 4 bandas en distintos canales:

Tabla 25. Organización de la información RGBI

Canal	Banda
0	Rojo
1	Verde
2	Azul
3	Infrarrojo cercano




Figura 30. Falso color sobre muestra de vegetación tras aplicar la información infrarroja

La obtención del valor del infrarrojo resulta importante, debido a que se trata de una de las características, para entrenar el modelo; por ejemplo, a partir de él, se obtiene el índice NDVI, imprescindible para clasificar la vegetación.

2.3.2.3. Clasificación manual: Realización de las muestras

Este apartado supone uno de los pasos más importantes del trabajo; de la calidad de las muestras depende el entrenamiento del modelo, y de ahí el resultado de la clasificación. Para ello, mediante el visor de descargas del CNIG, se seleccionaron diferentes zonas de interés y se procedió a descargar los bloques correspondientes y a unir la información RGB Y NIR (Puntos 2.3.2.1 y 2.3.2.2).

De estos ficheros se obtuvieron diferentes muestras de entrenamiento y validación que albergan puntos de las distintas clases a clasificar. La proporción de puntos obtenidos para entrenar y validar es de 75% y 25% aproximadamente. Al realizar las muestras, se han seleccionado zonas representativas, como áreas urbanas, zonas con edificaciones aisladas, naves industriales, suelo desnudo, bosques, cultivos, etc. Las clases consideradas son las siguientes: Suelo (2), Vegetación baja (3), Vegetación media (4), Vegetación alta (5), Edificios (6), Puntos bajos (11) y Artefactos sobre el suelo (13).

Tras obtener la zona de interés, se han de clasificar las muestras de forma manual. Parte de este trabajo está resuelto, ya que los bloques descargados desde el CNIG están clasificados, aunque esta clasificación debe ser refinada. Por lo tanto, el trabajo consiste en corregir los puntos erróneos de dicha clasificación. Además, a estas muestras se les ha incluido un buffer de 50 metros de puntos no clasificados (incluidos dentro de la clase 0, ejemplo en la figura 31), con el fin de que la librería CGAL sea capaz de calcular las diferentes características geométricas necesarias que han sido utilizadas en la metodología de clasificación seguida por Tracasa.




Figura 31. Ejemplo buffer de 50 metros

Este trabajo se ha realizado con el software TerraScan. Este software es la aplicación principal de la familia Terrasolid para administrar y procesar nubes de puntos LiDAR. La mayoría de estas aplicaciones de Terrasolid se basan en la plataforma Microstation de Bentley (Terrasolid, 2019).

Las muestras generadas (en versión 1.4 formato 8) se describen a continuación (Los mapas correspondientes se encuentran en el punto 6.3.)⁵:

⁵ Las siglas ME hacen referencia a las muestras de entrenamiento, MV, en cambio, las muestras de validación.

Tabla 26. Tabla-resumen de la obtención de muestras

Número	Lote	Cobertura	Año	Sensor	Densidad (p/m ²)
1	GAL E	2º	2015	ALS80	0,5
2	ARA CN y ARA SE	2º	2016 y 2018	ALS80	1
3	RIO	2º	2016	ALS80	2
4	VAL	1º	2009	RIEGL MLS-Q680i	0,5
5	VAL	2º	2015	RIEGL MLS-Q780	0,5

1. Leica ALS80 (Galicia Este)

Vuelo realizado entre julio y septiembre del año 2015, a una densidad de 0.5 p/m². Las muestras realizadas son las siguientes:

Tabla 27. Número de puntos para las muestras ALS80 a 0,5 p/m²

Clase	Nº puntos ME	Nº puntos MV
2	107893	23228
3	15728	5118
4	9654	2407
5	22312	10758
6	32746	9370
11	11	11
13	1462	227
Total	189806	51119

Tabla 29. Muestras de entrenamiento para ALS80 0.5 p/m². (En la figura 60, en azul)

Id	Nombre	Descripción
1	ME_GAL_1	Industrial
2	ME_GAL_2	Cultivos, edificación aislada
3	ME_GAL_3	Urbano
4	ME_GAL_4	Cultivos, edificación aislada
5	ME_GAL_5	Urbano
6	ME_GAL_6	Bosque
7	ME_GAL_7	Urbano
8	ME_GAL_8	Edificaciones aisladas
9	ME_GAL_9	Industrial, suelo
10	ME_GAL_10	Edificio
11	ME_GAL_11	Carretera, bosque
12	ME_GAL_12	Vegetación variada
13	ME_GAL_13	Edificio, vegetación variada
14	ME_GAL_15	Carretera
15	ME_GAL_16	Cultivos, suelo desnudo
16	ME_GAL_17	Cultivos
17	ME_GAL_18	Cultivos

Tabla 28. Muestras de validación para ALS80 0.5 p/m². (En la figura 60, en rojo)

Id	Nombre	Descripción
1	MV_GAL_1	Urbano
2	MV_GAL_2	Bosque
3	MV_GAL_3	Cultivos, suelo, edificación
4	MV_GAL_4	Edificaciones, vegetación variada
5	MV_GAL_5	Bosque

2. Leica ALS80 (Aragón CN y SE)

Vuelos realizados entre octubre y noviembre del año 2016 y el mes de septiembre del 2018, a una densidad de 1 p/m². Se ha optado por obtener muestras de dos lotes ya que representan zonas pequeñas de las que no es posible representar diferentes casos. Las muestras realizadas son las siguientes:

Tabla 30. Número de puntos para las muestras ALS80 a 1 p/m²

Clase	Nº puntos ME	Nº puntos MV
2	200627	57266
3	35421	8939
4	13421	6586
5	32390	21912
6	40432	35034
11	13	9
13	1052	550
Total	323356	130296

 Tabla 31. Muestras de validación para ALS80 1 p/m². (En la figura 61, en rojo)

Id	Nombre	Descripción
1	MV_ARA_1	Urbano
2	MV_ARA_2	Edificación, vegetación
3	MV_ARA_3	Bosque

 Tabla 32. Muestras de entrenamiento para ALS80 1 p/m². (En la figura 61, en azul)

Id	Nombre	Descripción
1	ME_ARA_1	Edificación, cultivos
2	ME_ARA_2	Industrial
3	ME_ARA_3	Edificaciones, vegetación
4	ME_ARA_4	Urbano
5	ME_ARA_5	Bosque, suelo desnudo
6	ME_ARA_6	Urbano
7	ME_ARA_7	Bosque, cultivos
8	ME_ARA_8	Carretera, suelo desnudo
9	ME_ARA_9	Edificación, vegetación variada
10	ME_ARA_10	Edificación, vegetación variada
11	ME_ARA_11	Industrial, vegetación
12	ME_ARA_12	Industrial, vegetación
13	ME_ARA_13	Edificación, carretera, suelo desnudo
14	ME_ARA_14	Carretera, vegetación variada
15	ME_ARA_15	Arbolado
16	ME_ARA_16	Arbolado

3. Leica ALS80 (La Rioja)

Vuelo realizado entre agosto y septiembre del año 2016, a una densidad de 2 p/m². Las muestras realizadas son las siguientes:

 Tabla 33. Número de puntos para las muestras ALS80 a 2 p/m²

Clase	Nº puntos ME	Nº puntos MV
2	408994	78497
3	36775	12331
4	63368	31627
5	55087	87281
6	65157	14430
11	43	2
13	1566	808
Total	630990	224976

 Tabla 34. Muestras de validación para ALS80 2 p/m². (En la figura 62, en rojo)

Id	Nombre	Descripción
1	MV_RIO_1	Urbano
2	MV_RIO_2	Edificación, vegetación
3	MV_RIO_3	Bosque, suelo desnudo
4	MV_RIO_4	Bosque

 Tabla 35. Muestras de validación para ALS80 2 p/m². (En la figura 62, en azul)

Id	Nombre	Descripción
1	ME_RIO_1	Urbano
2	ME_RIO_2	Edificaciones
3	ME_RIO_3	Edificaciones, vegetación variada
4	ME_RIO_4	Industrial
5	ME_RIO_5	Bosque
6	ME_RIO_6	Carretera, edificación
7	ME_RIO_10	Vegetación variada, suelo desnudo
8	ME_RIO_11	Vegetación variada, carretera
9	ME_RIO_12	Cultivos, suelo desnudo
10	ME_RIO_13	Industrial
11	ME_RIO_14	Cultivos, carretera
12	ME_RIO_15	Cultivos
13	ME_RIO_16	Bosque, suelo desnudo

4. Riegl Q-680 (Valencia, 1º cobertura)

Vuelo realizado entre agosto y septiembre del año 2009, a una densidad de 0,5 p/m². A pesar de ello, la densidad real es superior. Las muestras realizadas son las siguientes:

Tabla 36. Número de puntos para las muestras Riegl Q-680

Clase	Nº puntos ME	Nº puntos MV
2	169165	63909
3	8418	1953
4	12581	3364
5	31437	7615
6	46446	8896
11	33	2
13	1294	188
Total	269374	85927

Tabla 38. Muestras de entrenamiento para Riegl Q-680 (En la figura 63, en azul)

Id	Nombre	Descripción
1	ME_VAL1_1	Industrial
2	ME_VAL1_2	Cultivos
3	ME_VAL1_3	Urbano
4	ME_VAL1_4	Urbano, parking
5	ME_VAL1_5	Bosque, carretera, suelo desnudo
6	ME_VAL1_6	Bosque, carretera
7	ME_VAL1_7	Vegetación variada
8	ME_VAL1_8	Cultivos
9	ME_VAL1_9	Arbolado
10	ME_VAL1_10	Edificación, suelo desnudo
11	ME_VAL1_11	Bosque, carretera
12	ME_VAL1_12	Cultivos
13	ME_VAL1_13	Edificaciones, vegetación variada
14	ME_VAL1_14	Bosque, pista
15	ME_VAL1_15	Carretera, suelo desnudo
16	ME_VAL1_16	Industrial

Tabla 37. Muestras de validación para Riegl Q-680 (En la figura 63, en rojo)

Id	Nombre	Descripción
1	MV_VAL1_1	Urbano
2	MV_VAL1_2	Vegetación variada
3	MV_VAL1_3	Urbano, vegetación variada

5. Riegl Q-780 (Valencia)

Vuelo realizado entre octubre y noviembre del año 2015, a una densidad de 0,5 p/m². Como en la cobertura anterior, la densidad real es superior. Las muestras realizadas son las siguientes:

Tabla 39. Número de puntos para las muestras Riegl Q-780

Clase	Nº puntos ME	Nº puntos MV
2	164831	46355
3	30318	9560
4	27651	11683
5	37386	20431
6	85275	10345
11	9	1
13	2394	391
Total	347864	98766

Tabla 41. Muestras de entrenamiento para Riegl Q-780 (En la figura 64, en azul)

Id	Nombre	Descripción
1	ME_VAL2_1	Edificaciones, vegetación variada
2	ME_VAL2_2	Cultivos, arbolado
3	ME_VAL2_3	Urbano
4	ME_VAL2_4	Industrial, carretera
5	ME_VAL2_5	Urbano
6	ME_VAL2_6	Suelo desnudo
7	ME_VAL2_7	Cultivos, suelo desnudo
8	ME_VAL2_8	Cultivos, vegetación variada
9	ME_VAL2_9	Carretera, suelo, edificio aislado
10	ME_VAL2_10	Industrial
11	ME_VAL2_11	Urbano
12	ME_VAL2_12	Edificios, vegetación variada
13	ME_VAL2_13	Vegetación variada
14	ME_VAL2_14	Industrial

Tabla 40. Muestras de validación para Riegl Q-680 (En la figura 64, en rojo)

Id	Nombre	Descripción
1	MV_VAL2_1	Urbano
2	MV_VAL2_2	Vegetación variada, edificio aislado
3	MV_VAL2_3	Urbano, vegetación
4	MV_VAL2_4	Bosque

2.3.2.4. Entrenamiento de los puntos

El primer paso del entrenamiento consiste en obtener diferentes ficheros CSV para todas las muestras. Estos CSV obtienen información de las diferentes características utilizadas para

cada punto en la metodología de clasificación de Navarra. Esto es posible gracias a la herramienta *las-samples2csv* (Figura 32); para obtener dichos CSV, se ha de especificar el directorio de ficheros LAS/LAZ de los que queremos obtener la información, en este caso, de las muestras de entrenamiento y validación donde se encuentran las muestras generadas (Punto 2.3.3) y el directorio de salida.

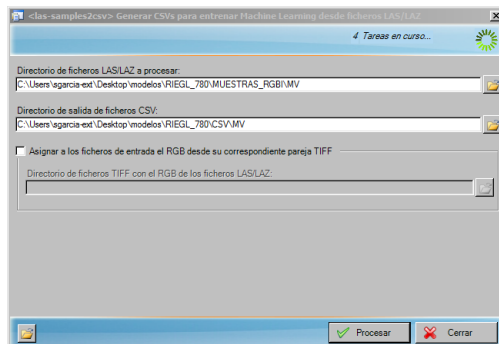


Figura 32. Programa *las-samples2csv*

Estos CSV contienen información indispensable para entrenar el algoritmo, por lo que en la herramienta *las-train2las* (Figura 33), cargaremos dicha información, tanto de las muestras de entrenamiento como las de validación por separado. Con ello, el programa obtiene los diferentes parámetros con los que entrenar los modelos. El algoritmo utilizado en todos los casos es el XGBoost.

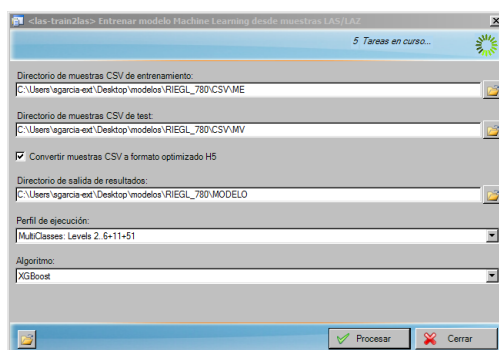


Figura 33. Programa *las-train2las*

El resultado del modelo se guarda en un fichero .model. El programa también genera un XLSX en el que es posible observar diferentes parámetros que describen y evalúan la calidad del modelo.

2.3.2.5. Clasificación de los puntos

Una vez entrenado los algoritmos, es posible clasificar cualquier fichero LAS o LAZ. Para ello, el programa *las-classify2las* (Figura 34) es capaz de clasificar cualquier directorio de ficheros LAS/LAZ con un modelo cualquiera generado en el punto anterior (2.3.2.4). En él, se han de insertar los diferentes parámetros:

- Directorio de ficheros LAS/LAZ a procesar, es decir, los bloques que queremos clasificar. Estos bloques deben de incluir la información RGBI, por lo que, en el caso de tener esa información por separado, es necesario utilizar la herramienta *las-join-rgbnir-ignspain* (Punto 2.3.2.2).
- Directorio de salida de los ficheros a clasificar.

- Formato de los ficheros de salida: LAS o LAZ.
- Fichero donde se guarda la información del modelo, generado en el punto 2.3.2.4.

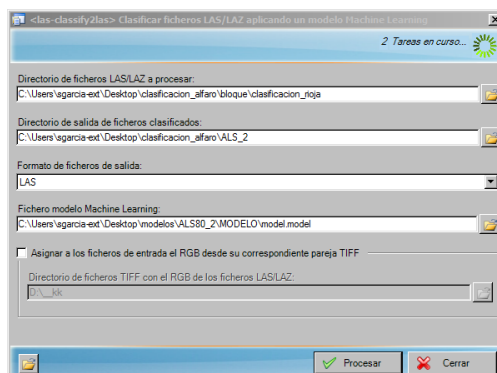


Figura 34. Programa las-classify2las

El resultado final del programa es un fichero LAS/LAZ⁶ clasificado por el modelo escogido.

2.3.2.6. Validación de los puntos con la herramienta

Para poder realizar la validación, es necesario poseer algún bloque clasificado previamente de forma precisa que sirva de referencia para comparar punto por punto. Para ello, el primer paso es justamente clasificar de forma precisa un bloque. Para este trabajo, se ha optado por el bloque PNOA-2016-RIO-602-4670-ORT-CLA.laz (Figura 35), situado en el término municipal de Alfaro (La Rioja), que ocupa un área de 2x2 km. Este bloque pertenece a la segunda cobertura de La Rioja, que fue obtenida con el sensor ALS80 a una densidad de 2 p/m².

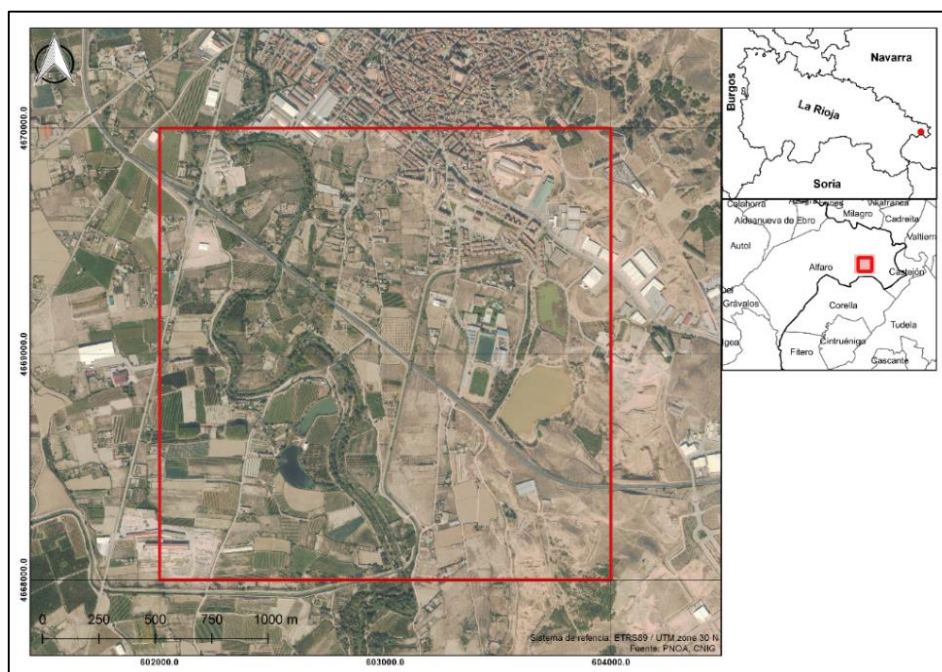


Figura 35. Mapa localización del bloque 602-4670 (Alfaro, La Rioja)

⁶ O más, ya que se pueden incluir directorios enteros.

Se trata de un bloque de interés, ya que cumple las siguientes condiciones:

- Es posible comparar los modelos de clasificación generados con el mismo sensor a diferentes densidades; en este caso, el bloque fue obtenido con el sensor ALS80 a una densidad de 2 p/m², que podrá ser comparado con el mismo sensor a una densidad menor.
- Podrá evaluarse el modelo de clasificación obtenido con distintos sensores y densidades.

Este trabajo ha sido realizado mediante el software TerraScan. A continuación, en la figura 36, se muestra el resultado de la clasificación precisa del bloque 602-4670:




Figura 36. Clasificación precisa del bloque 602-4670. En naranja, suelo; en verde, vegetación; en naranja, suelo y en blanco, artefactos sobre el suelo

Las principales correcciones entre clases se deben a estas dos causas:

- En las zonas de borde de los edificios, gran parte de los puntos se clasificaban como vegetación media y sobre todo alta, por lo que parte de los puntos de vegetación han pasado a clasificarse como edificios (Figuras 37 y 38).




Figura 37. Bordes de edificios mal clasificados como vegetación alta (en verde oscuro)




Figura 38. Bordes de edificios bien clasificados (en rojo)

- Puntos de vegetación baja y media han pasado a la clase de artefactos sobre el suelo. En este caso, los vehículos se clasificaban como vegetación debido a que la diferencia de altura sobre el suelo se encuentra entre los rangos de vegetación baja y sobre todo, media (Figuras 39 y 40).




Figura 39. Automóviles mal clasificados como vegetación media (en verde pistacho)




Figura 40. Automóviles bien clasificados (en blanco)

No se han tenido en cuenta otras clases presentes en el bloque descargado, por lo que fueron eliminados los puntos de las clases sin clasificar, ruido y solape que se incluían en el bloque.

Tras la obtención de un bloque de referencia, se ha de pasar a la fase de validación, donde se utiliza el programa *las-discrepancy2csv* con el fin de comparar los dos bloques.

3. RESULTADOS

En este capítulo, se muestran los resultados obtenidos. Estos están separados en varios apartados; por un lado, en el 3.1, se evalúa la clasificación obtenida en el caso de dos modelos entrenados a partir de muestras de los sensores ALS80 y Riegl Q-680. Por otro lado, en el apartado 3.2, se evalúa la clasificación obtenida en el modelo a partir de todas las muestras generadas en este estudio. En el apartado 3.3 se realiza un análisis de los resultados de manera general para las tres clasificaciones realizadas.

En primer lugar, se muestra el resultado del entrenamiento del modelo y el de la clasificación. Los resultados del entrenamiento se encuentran en un fichero XLSX generado al entrenar el modelo (Página 41). La clasificación, en cambio, es evaluada mediante la herramienta de validación generada⁷, utilizando el bloque RIO-602-4670 (Alfaro, La Rioja) de referencia. De esta manera, las fases de clasificación y validación de datos LiDAR, la base de este trabajo, se unen en un mismo caso de estudio.

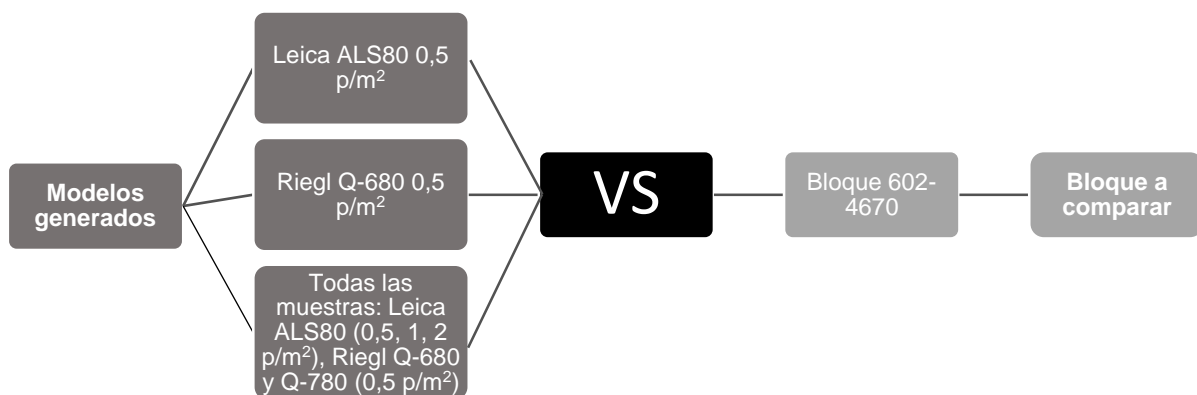


Figura 41. Esquema de los modelos obtenidos y su validación

Parte de los resultados (los no correspondientes a la validación de los puntos ponderando el tipo de error) se encuentran en el Anexo 6.4.

3.1. Validación del bloque con los modelos generados

En este apartado se validarán los dos primeros modelos; Leica ALS80 y Riegl Q-680, los dos a una densidad de 0,5 p/m² (Figura 41).

3.1.1. Resultados obtenidos en las áreas de entrenamiento

A continuación, se muestran los resultados obtenidos al entrenar los modelos (Punto 2.3.2.4). Para ello, se han obtenido diferentes métricas de rendimiento, tanto generales del modelo y por clases.

En el caso del modelo ALS80 a una densidad de 0,5 p/m², se ha obtenido un *Accuracy* de 0,9693 en el entrenamiento.

⁷ Al ejecutar el programa *las-discrepancy2csv*, el voxel escogido es de 1 metro para todos los casos (por defecto).

Tabla 42. Resultados de las muestras de entrenamiento al obtener el modelo de los datos de ALS80 a 0,5 p/m²

Clase	Precision	Recall	f1-score
2	0,96	0,99	0,98
3	0,94	0,7	0,8
4	0,98	0,95	0,97
5	1	1	1
6	1	1	1
11	0	0	0
13	0,99	0,99	0,99

Medida	Precision	Recall	F1-score
Macro avg	0,84	0,81	0,82
Weighted avg	0,97	0,97	0,97

En cambio, en el caso del modelo Riegl Q-680 a una densidad de 0,5 p/m², se ha obtenido un *Accuracy* de 0,9982 en el entrenamiento.

Tabla 43. Resultados de las muestras de entrenamiento al obtener el modelo de los datos de Riegl Q-680 a 0,5 p/m²

Clase	Precision	Recall	f1-score
2	1	1	1
3	0,99	0,95	0,97
4	1	1	0,99
5	1	1	1
6	1	1	1
11	0	0	0
13	1	0,99	1

Medida	Precision	Recall	F1-score
Macro avg	0,85	0,85	0,85
Weighted avg	1	1	1

3.1.2. Validación de los datos de ALS80 a 0,5 p/m² sobre el bloque de referencia

A continuación, se muestran los resultados obtenidos tras comparar el bloque clasificado por el modelo y el bloque de referencia:




Figura 42. Bloque clasificado por el modelo ALS80 a 0,5 p/m²

3.1.2.1. Estadísticas estándar

Un total de 1164107 puntos han sido mal clasificados, lo que supone un 14,11% sobre el total.

- **Total de puntos del bloque:** 8249166
- **Total de puntos erróneos:** 1164107
- **Porcentaje puntos erróneos:** 14,11%

En la tabla 44, se muestran los errores cometidos por clase. En el caso de las clases 13 y 3, gran parte de sus puntos han sido clasificados erróneamente. Sobre el total de puntos erróneos, entre la clase 2 y 3 se reúnen el 75,9% de los fallos.

Tabla 44. Errores por clase

Clase	Errores	Nº total de puntos	% error sobre el total de puntos (de esa misma clase)	% sobre el total de puntos erróneos
2	423540	5690641	7,44	36,38
3	460005	705795	65,18	39,52
4	35631	567200	6,28	3,06
5	54358	741460	7,33	4,67
6	179766	531217	33,84	15,44
11	0	0	0	0,00
13	10807	12853	84,08	0,93
Total	1164107	8249166		100,00

3.1.2.2. Estadísticas por tipos de error

En las siguientes tablas (45 y 46), los errores son agrupados respecto a la gravedad de error según la puntuación obtenida a partir de los diferentes parámetros (Tabla 17). En este apartado, los resultados únicamente se muestran en porcentajes, para un mejor análisis de los datos⁸.

Tabla 45. Porcentaje correspondiente a cada tipo de error por clase

Clases	No problema	Leve	Algo grave	Grave	Muy grave	Total	Tipo de error mayoritario por clase
2	69,02	18,26	5,02	7,67	0,03	100	No problema
3	49,66	46,65	2,72	0,97	0,00	100	No problema
4	18,40	58,99	22,50	0,11	0,00	100	Leve
5	18,76	51,79	29,03	0,40	0,02	100	Leve
6	0,61	25,72	42,88	30,68	0,11	100	Algo grave
11	0,00	0,00	0,00	0,00	0,00	-	-
13	5,02	78,99	15,97	0,03	0,00	100	Leve

En la tabla 45 se aprecia que la clase de edificios posee gran parte de sus puntos como errores importantes (Muy grave, grave y algo grave). En este bloque, algunos puntos de suelo han sido clasificados como edificios en zonas en lo alto de colinas (Ver figura 43).

⁸ Las tablas con los números enteros se encuentran en el punto 6.4 (Anexo IV: Resultados de las clasificaciones) tanto para este modelo como para los siguientes.




Figura 43. Ejemplo de puntos mal clasificados de edificios (en rojo) sobre suelo (en naranja)

Parte de los puntos de suelo mal clasificados considerados graves corresponden a tejados de pabellones industriales (Figura 44). La gravedad de este caso es alta, ya que, por lo general, el tejado de este tipo de edificaciones se encuentra a varios metros sobre el MDT.




Figura 44. Puntos de la clase suelo mal clasificados sobre tejados (en naranja)

En este bloque, los errores que no suponen problemas y los leves reúnen un total de 80,31% de los puntos erróneos (Ver tabla 46). La mayoría de estos errores describen los casos de confusión en las clases suelo y vegetación baja. Respecto a la clase suelo, estos errores no graves surgen de la confusión con la clase vegetación baja. En cuanto a la clase de vegetación baja, los errores no graves corresponden a la confusión con las clases de suelo y vegetación media. Los errores muy graves o graves reúnen un 7,97% del total de errores.

Tabla 46. Porcentaje de errores según el tipo de error

Tipo error	Total	% sobre el total de puntos	% sobre el total de errores
No problema	539131	6,54	46,31
Leve	395833	4,80	34,00
Algo grave	136396	1,65	11,72
Grave	92398	1,12	7,94
Muy grave	349	0,004	0,03
	1164107		100,00

3.1.2.3. Errores groseros

En este último apartado, se muestran los denominados errores groseros. En este caso, un 4,59% del total de puntos erróneos se consideran como tal, por lo que su altura respecto al MDT es desproporcionada de acuerdo a la clase a la que pertenecen. En este caso, la mayoría de estos puntos se recogen en las clases 2 y 3.

Tabla 47. Errores groseros

Clase	Altura superior	Altura inferior	% errores groseros sobre el total de fallos de esa misma clase
2	38314	53	9,059
3	13549	10	2,948
4	166	139	0,856
5	-	19	0,035
6	-	1122	0,624
11	0	-	0,000
13	-	3	0,028
Total errores groseros %		Total de errores groseros	Total sobre todos los puntos erróneos
		53375	4,59

Gran parte de los puntos de la clase 2 asignados como puntos erróneos con altura superior al MDT corresponden a aquellos que confunden los tejados de pabellones industriales, como se ha podido observar en la figura 43.

3.1.3. Validación de los datos de Riegl Q-680 a 0,5 p/m² sobre el bloque de referencia

A continuación, se muestran los resultados obtenidos tras comparar el bloque clasificado por el modelo y el bloque de referencia:




Figura 45. Resultado obtenido por el modelo Riegl Q-680

3.1.3.1. Estadísticas estándar

Un total de 1876683 puntos han sido mal clasificados, lo que supone un 22,75% sobre el total.

- **Total de puntos del bloque:** 8249166
- **Total de puntos erróneos:** 1876678
- **Porcentaje puntos erróneos:** 22,75%

Tabla 48. Errores por clase

Clase	Errores	Nº total de puntos de esa clase	% error sobre el total de puntos (de esa misma clase)	% sobre el total de puntos erróneos
2	941821	6400847	14,71	50,19
3	74636	75305	99,11	3,98
4	11843	312173	3,79	0,63
5	20575	319637	6,44	1,10
6	765898	1070193	71,57	40,81
11	0	0	0	0,00
13	61910	71011	87,18	3,30
Total	1876683	8249166		100,00

En la tabla 48, se muestran los errores cometidos por clase. En el caso de las clases 3, 13 y 6, gran parte de sus puntos han sido clasificados erróneamente. Sobre el total de puntos erróneos, entre la clase 2 y 6 se aglutinan más del 90% de los fallos.

Con este modelo, no se han clasificado correctamente los puntos de la clase 3, además de que posee un número bajo de estos ejemplos (un total de 75305 puntos, de los que el 99% han sido mal clasificados).

La mayoría de los puntos de la clase 13 han sido clasificados erróneamente (87,18%); en general, estos corresponden a la clase de vegetación media. Esto se da en zonas cultivadas con patrones regulares (Figura 46).




Figura 46. Puntos de la clase artefactos sobre suelo mal clasificados (en blanco) y bien clasificados (al fondo, verde pistacho)

Gran parte de los puntos de edificios también son erróneos (71,57%). En esta clasificación, algunas masas arboladas y densas, como choperas, han sido clasificadas totalmente como clase 6 (Figura 47).

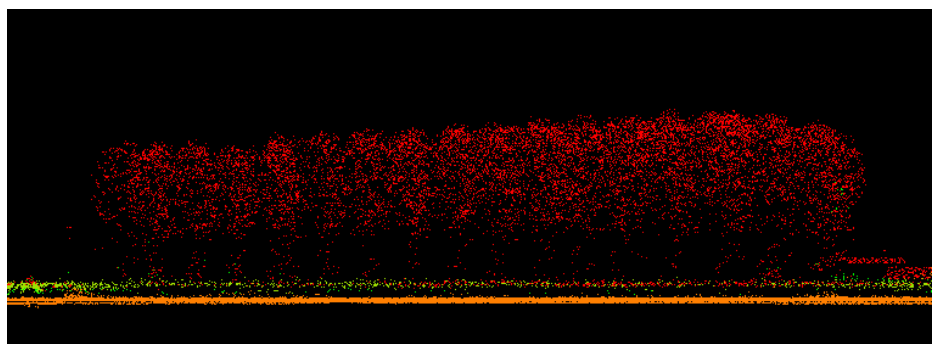


Figura 47. Puntos de edificios (en rojo) mal clasificados

3.1.3.2. Estadísticas por tipos de error

En las siguientes tablas (49 y 50) los errores se agrupan respecto a los tipos de error posibles (Tabla 16).

Tabla 49. Porcentaje correspondiente a cada tipo de error por clase

Clases	No problema	Leve	Algo grave	Grave	Muy grave	Total	Tipo de error mayoritario por clase
2	52,95	24,30	14,40	8,31	0,04	100	No problema
3	0,59	70,03	28,33	1,04	0,01	100	Leve
4	25,34	52,82	21,70	0,14	0,00	100	Leve
5	27,84	59,63	12,17	0,31	0,05	100	Leve
6	0,11	23,60	51,81	24,27	0,21	100	Algo grave
11	0,00	0,00	0,00	0,00	0,00	0	-
13	16,08	77,79	6,12	0,00	0,00	100	Leve

En la tabla 49 se aprecia que en la clase de edificios el porcentaje de los errores importantes (Muy grave, grave y algo grave) es superior. Esto se debe a dos casos; por un lado, puntos de clase de edificios (6) correspondientes a la clase suelo (2). En este bloque, puntos de suelo han sido clasificados como edificios en zonas de grandes pendientes (Ver figura 48).




Figura 48. Puntos de la clase edificios mal clasificados en zonas con pendiente (en rojo)

Otro de los casos corresponde a las masas de vegetación clasificadas como edificios. La gran parte de los errores leves de esta clase 6 (un 23,6%) corresponden a la confusión de esta clase con la de vegetación alta, como se aprecia en la figura 47.

En menor medida, los errores graves corresponden a puntos de suelo mal clasificados. Esto ocurre sobre tejados de pabellones industriales (Figura 49). Estos puntos de suelo son considerados graves debido a que se encuentran a varios metros de diferencia sobre el MDT.




Figura 49. Puntos de la clase suelo mal clasificados sobre tejados (en naranja)

En este bloque, los errores muy graves o graves reúnen un 14,23% del total de los errores, lo que supone un total de 3,27% del total de puntos (Ver tabla 50).

Tabla 50. Porcentaje de errores según el tipo de error

Tipo error	Nº de puntos	% sobre el total de puntos	% sobre el total de errores
No problema	518632	6,287	27,64
Leve	528536	6,407	28,16
Algo grave	562432	6,818	29,97
Grave	265079	3,213	14,12
Muy grave	2004	0,024	0,11
Total	1876683		100,00

3.1.3.3. Errores groseros

En la tabla 51, se muestran los puntos mal clasificados considerados como groseros. En este caso, un 7,56% del total de puntos erróneos se consideran como tal. La mayoría de estos puntos pertenecen a la clase suelo, que en este caso, se encuentran a una altura superior a 1,5 metros. Cabe destacar el porcentaje de este tipo de puntos de la clase 4 respecto al total de sus puntos erróneos. En este caso, estos puntos corresponderían a la clase de vegetación alta.

Tabla 51. Errores groseros

Clase	Altura superior	Altura inferior	% errores groseros sobre el total de fallos de esa misma clase
2	127254	66	13,518
3	9817	1	13,155
4	3371	2	28,481
5	-	2	0,010
6	-	1439	0,188
11	0	-	0,000
13	-	0	0,000
Total errores groseros		Total de errores groseros	Total sobre todos los puntos erróneos (%)
		141952	7,56

3.2. Validación del bloque con el modelo generalista de clasificación

En este segundo apartado, se muestran los resultados obtenidos en el modelo generado a partir de las muestras de los distintos sensores (ALS80, Riegl Q-680 y Q-780) y distintas densidades disponibles (0,5, 1 y 2 p/m²).

3.2.1. Resultados obtenidos en las áreas de entrenamiento

Tras entrenar el modelo a partir de 76 muestras de entrenamiento y 19 de validación (Punto 2.3.2.4), correspondientes a todas las generadas para diferentes sensores y densidades, se ha obtenido un modelo que ha logrado las siguientes métricas (Tabla 44). En general, este modelo ha obtenido un valor de *Accuracy* de 0,9365 en el entrenamiento.

Tabla 52. Resultados de las muestras de entrenamiento del modelo obtenido a partir de todas las muestras

Clase	Precision	Recall	f1-score
2	0,93	0,99	0,96
3	0,8	0,39	0,52
4	0,91	0,9	0,91
5	0,98	0,98	0,98
6	0,98	0,97	0,98
11	1	0,31	0,48
13	0,94	0,89	0,92

Medida	Precision	Recall	f1-score
Macro avg	0,93	0,78	0,82
Weighted avg	0,93	0,94	0,93

3.2.2. Validación sobre el bloque de referencia

A continuación, se muestran los resultados obtenidos tras comparar el bloque clasificado por el modelo y el bloque de referencia:




Figura 50. Bloque clasificado mediante el modelo generalista de clasificación

3.2.2.1. Estadísticas estándar

Un total de 941378 puntos han sido mal clasificados, lo que supone un 11,41% sobre el total.

- **Total de puntos del bloque:** 8249166
- **Total de puntos erróneos:** 941378
- **Porcentaje puntos erróneos:** 11,41%

En la tabla 53, se muestran los errores cometidos por clase. En el caso de las clases 11 y 13, gran parte de sus puntos han sido clasificados erróneamente (80 y 86%, respectivamente). Sobre el total de puntos erróneos, la clase 2 aglutina el 60% del total de los fallos, sin embargo, no llegan a suponer el 10% de puntos erróneos de su misma clase.

Tabla 53. Errores por clase

Clase	Errores	Nº total de puntos de esa clase	% error sobre el total de puntos de esa clase	% sobre el total de puntos erróneos
2	567510	6113087	9,28	60,29
3	91063	232412	39,18	9,67
4	53199	666233	7,99	5,65
5	32029	682542	4,69	3,40
6	191401	547711	34,95	20,33
11	8	10	80,00	0,00
13	6168	7171	86,01	0,66
Total	941378	8249166		100,00

Respecto a la clase 13, gran parte de estos puntos han sido confundidos con zonas de cultivos de vegetación media, como se puede apreciar en la figura 51.




Figura 51. Puntos de la clase 13 erróneos (en blanco)

3.2.2.2. Estadísticas por tipos de error

En las dos siguientes tablas (54 y 55), se agrupan las clases según los tipos de error respecto a la puntuación obtenida. Como en los otros casos, los resultados únicamente se muestran en porcentajes.

Tabla 54. Porcentaje correspondiente a cada tipo de error por clase

Clases	No problema	Leve	Algo grave	Grave	Muy grave	Total	Tipo de error mayoritario por clase
2	65,35	21,42	7,37	5,85	0,01	100	No problema
3	50,86	40,90	4,97	3,26	0,01	100	No problema
4	21,16	62,40	16,24	0,20	0,00	100	Leve
5	19,71	42,88	37,15	0,25	0,01	100	Leve
6	0,60	30,42	40,20	28,63	0,14	100	Algo grave
11	33,33	66,67	0,00	0,00	0,00	100	Leve
13	19,00	73,96	7,00	0,03	0,00	100	Leve

Como se puede ver en la tabla 54, la clase 6 obtiene un porcentaje superior de errores importantes (Muy grave, grave y algo grave) en comparación a las demás clases. Estos fallos corresponden a zonas de suelo clasificados como edificios. En estos casos, son pequeñas zonas de suelo donde existe desnivel, como se puede apreciar en la figura 52.




Figura 52. Ejemplo de puntos mal clasificados de edificios (en rojo) sobre suelo (en naranja)

Tras ella, se sitúa la clase suelo. Los errores más graves corresponden a la confusión entre los tejados de pabellones industriales con suelo. La gravedad radica en la diferencia de altura existente entre el MDT y aquellos puntos de la clase suelo erróneos (Figura 53).




Figura 53. Ejemplo de puntos de suelo (en naranja) sobre tejados altos (en rojo)

Tabla 55. Porcentaje de errores según el tipo de error

Tipo error	Nº de puntos	% sobre el total de puntos	% sobre el total de errores
No problema	437052	5,30	46,43
Leve	268507	3,25	28,52
Algo grave	144293	1,75	15,33
Grave	91171	1,11	9,68
Muy grave	355	0,004	0,04
Total	941378		100,00

En este bloque, los errores que no suponen problemas y los leves reúnen un total de 74,95% de los puntos erróneos (Ver tabla 55). La mayoría de estos errores describen los casos de confusión entre suelo y vegetación baja y los errores entre los distintos tipos de vegetación (baja, media y alta). En cambio, los errores graves describen las confusiones entre suelo y edificios y viceversa.

3.2.2.3. Errores groseros

En este último apartado, se muestran los puntos erróneos considerados groseros. Un 5,52% del total de erróneos se consideran como tal, es decir, poseen alturas no acordes a la clase a la que fueron asignados. En este caso, la mayoría de estos puntos se aglutinan en las clases suelo y vegetación baja.

Tabla 56. Errores groseros

Clase	Altura superior	Altura inferior	% errores groseros sobre el total de fallos de esa misma clase
2	44938	80	7,933
3	5808	3	6,381
4	250	221	0,885
5	-	3	0,009
6	-	633	0,331
11	0	-	0,000
13	-	2	0,032
Total errores groseros %		Total de errores groseros	Total sobre todos los puntos erróneos (%)
		51938	5,52

Gran parte de los puntos de la clase 2 asignados como puntos erróneos con altura superior al MDT corresponden a aquellos que confunden los tejados de pabellones industriales, como se ha podido observar en la figura 53.

3.3. Análisis de los resultados

En general, en los 3 bloques clasificados por los diferentes modelos, poseen un mismo patrón de errores, que serán explicados a continuación.

En los tres casos, el mayor porcentaje de error sobre el total de puntos por cada clase corresponde a las categorías de artefactos sobre el suelo, edificios y vegetación baja. Respecto a la clase de puntos bajos, que solo ha llegado a clasificarse en el bloque clasificado por el modelo obtenido por todas las muestras, gran parte de sus puntos también resultan erróneos.

En relación a los tipos de error, también se mantiene el mismo patrón. En las clases de edificaciones y suelo se dan los tipos de error más graves. Por un lado, los puntos de edificaciones son confundidos con el suelo, generalmente en zonas de alto desnivel, ocupando pequeñas zonas. Por otro lado, los puntos de suelo erróneos considerados graves⁹, se confunden con tejados de pabellones industriales. En estos dos casos, se tratan de agrupaciones de puntos y no de puntos aislados.

En cambio, aquellos que no resultan importantes corresponden a confusiones entre la clase suelo y vegetación baja y media en algunos casos, además de las combinaciones posibles entre las diferentes clases de vegetación.

En el caso en el que la evaluación se hubiese basado únicamente en métricas estándar, como la Fiabilidad Global, el modelo obtenido a partir de todos los datos sería el mejor. En cambio, a pesar de obtener un menor número de errores, el porcentaje de puntos considerados graves y groseros de este bloque es superior al bloque clasificado por el modelo de ALS80 (Tabla

⁹ Hace referencia a errores considerados como muy graves, graves o algo graves.

57). En este caso, es posible que este modelo sea el mejor, que a pesar de que contiene más fallos, estos son de menor gravedad, lo que afectaría de menor manera en la generación de cualquier producto cartográfico.

Tabla 57. Resumen de los resultados obtenidos

Modelo	Densidad (p/m ²)	Fiabilidad Global	% tipo de error			% errores groseros
			Algo grave	Grave	Muy grave	
Leica ALS80	0,5	0,86	11,72	7,94	0,03	4,59
Riegl Q-680	0,5	0,77	29,97	14,12	0,11	7,56
Leica ALS80; Riegl Q-680 y Q-780	0,5, 1 y 2	0,89	15,33	9,68	0,04	5,52

4. CONCLUSIONES

4.1. Conclusiones generales

A continuación, se muestran las conclusiones obtenidas en este trabajo. Siguiendo el esquema de la investigación, las conclusiones se dividen en dos apartados según el objetivo cumplido.

4.1.1. Validación

En este trabajo, se ha desarrollado una metodología de validación que tiene en cuenta la gravedad de cada error, por lo que gracias a las conclusiones que se pueden extraer de los resultados, es posible prescindir de una validación visual de los bloques clasificados.

- En la metodología propuesta, es posible observar el tipo de gravedad de los errores de forma global y por clase.
- La metodología de validación propuesta es aplicable a cualquier dato LiDAR proveniente del PNOA.
- El problema de este método recae en la obtención de datos de referencia compatibles con los resultados de la clasificación. Para ello, se debe obtener un bloque perfectamente clasificado, lo que supone un trabajo laborioso. Además, para obtener unos buenos datos de referencia, resulta imprescindible conocer adecuadamente las características del terreno.
- Estas métricas que evalúan la gravedad de cada error reemplazan la necesidad de una inspección visual y se agregan a las métricas de evaluación estándar.

4.1.2. Clasificación

En general, no existe un consenso para los métodos de clasificación automática de nubes de puntos LiDAR, por lo que, en este trabajo, se ha utilizado el método de clasificación utilizado por Tracasa para la clasificación de la segunda cobertura del PNOA en la Comunidad Foral de Navarra. Tras generar modelos de clasificación con otros datos provenientes de diferentes lotes, se deduce lo siguiente:

- Teniendo en cuenta que en los casos de los modelos obtenidos a partir de las muestras del ALS80 y Q-680 poseen la misma densidad, se puede deducir que la tecnología utilizada y el patrón de escaneo afectan en los resultados de la clasificación. Cabe destacar que las muestras obtenidas del sensor de Leica poseen un patrón de escaneo en zig-zag, en cambio, las del sensor de Riegl, de líneas paralelas.
- En la clasificación realizada en Navarra, se utilizó como información adicional la delimitación de los edificios de forma vectorial, lo que mejoraba considerablemente la clasificación de la clase edificios (6). En cambio, en este trabajo, al no utilizar información ajena al vuelo, parte de los puntos erróneos corresponden a puntos de edificaciones etiquetados como suelo. Esto suele ocurrir en los tejados de pabellones industriales.
- Debido a la previa depuración y clasificación de los puntos provenientes del PNOA, resulta difícil encontrar ejemplos de la clase de puntos bajo el suelo (11) con los que entrenar el modelo, por lo que no se han podido clasificar puntos de esta clase. Además, la configuración seguida no utiliza el balanceo de datos, por lo que se tiende a favorecer las clases con la mayor proporción de ejemplos.
- La clasificación de puntos con la clase de artefactos sobre el suelo (13) creada para este trabajo resulta muy complicado, ya que se aglutinan objetos de diferente naturaleza en una única clase.

- A pesar de ir generando más muestras según los resultados obtenidos en distintas pruebas (como es el caso de zonas de pendiente y pabellones industriales), resulta muy difícil clasificar correctamente este tipo de superficies.

4.2. Aportaciones del trabajo y futuras líneas de investigación

Un trabajo de investigación permite obtener unos resultados y conclusiones que ayudan a contrastar la hipótesis planteada, pero, a su vez, genera nuevas preguntas, necesidades o líneas de investigación y trabajo.

Esta investigación describe un punto de partida en el uso de la metodología de validación propuesta, además de realizar modelos de clasificación a partir de los datos disponibles en el PNOA. Las líneas propuestas son:

- La automatización del proceso de validación, ya que hasta este punto, este proceso se ha dividido por partes para poder observar los resultados en cada fase. De esta manera, el único trabajo a realizar sería la clasificación manual del bloque de referencia.
- Se propone que en la automatización de todo el proceso exista la posibilidad de ajustar distintos parámetros, como los valores de las funciones y matrices de coste para ofrecer el error deseado por el usuario.
- Debido a los resultados obtenidos para la clase de artefactos sobre el suelo, se recomienda separar los puntos pertenecientes a la clase 13 en diferentes clases, en las que, por ejemplo, la altura de esos objetos se asemeje, con el fin de obtener un mejor resultado.
- Se han de realizar más muestras de todo tipo de casuísticas presentes en el territorio, debido a la heterogeneidad del mismo, para entrenar un modelo generalista de clasificación, además de incluir muestras de otros sensores disponibles en el PNOA, también pertenecientes a las familias de Leica y Riegl.

5. REFERENCIAS

- ASPRS. (2003). *ASPRS LIDAR Data Exchange Format Standard, Version 1.0*. 1–9. Retrieved from http://www.asprs.org/a/society/committees/standards/asprs_las_format_v10.pdf
- ASPRS. (2005). *Las Specification Version 1.1*. 1–11. <https://doi.org/faf>
- ASPRS. (2008). *LAS Specification Version 1.2*. 1–13. Retrieved from http://asprs.org/a/society/committees/standards/asprs_las_format_v12.pdf
- ASPRS. (2010). *LAS Specification Version 1.3*. 1–18. Retrieved from http://www.asprs.org/a/society/committees/standards/LAS_1_3_r11.pdf
- ASPRS. (2013). *LAS Specification Version 1.4*. (November 2011), 1–28. <https://doi.org/faf>
- Baltsavias. (1999a). A comparison between photogrammetry and laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 83–94. [https://doi.org/10.1016/S0924-2716\(99\)00014-3](https://doi.org/10.1016/S0924-2716(99)00014-3)
- Baltsavias. (1999b). Airborne laser scanning: Basic relations and formulas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 199–214. [https://doi.org/10.1016/S0924-2716\(99\)00015-5](https://doi.org/10.1016/S0924-2716(99)00015-5)
- Bishop, C. (2006). *Pattern Recognition and Machine Learning* (1st ed.). Springer-Verlag New York.
- Breiman, L. (2001). Random forests. *Machine Learning*, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chehata, N., Guo, L., & Mallet, C. (2009). Airborne LiDAR feature selection for urban classification using random forests. *IAPRS*, 38. <https://doi.org/10.13203/j.whugis20130206>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *KDD'16*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chuvieco, E. (1996). *Fundamentos de Teledetección Espacial (2ª Ed)*. Madrid: Ediciones Rialp, S. A.
- CNIG. (2019). El centro de descargas del CNIG. Retrieved July 16, 2019, from <http://centrodedescargas.cnig.es/CentroDescargas/index.jsp>
- Cochran, J. J., Cox, L. A., Keskinocak, P., Kharoufeh, J. P., Smith, J. C., & Goldszmidt, M. (2011). Bayesian Network Classifiers. *Wiley Encyclopedia of Operations Research and Management Science*, 163, 131–163. <https://doi.org/10.1002/9780470400531.eorms0099>
- Congalton, R. G., & Green, K. (2008). *Assesing the accuracy of Remotely Sensed Data* (2nd ed.). CRC Press.
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 297(20), 273–297. <https://doi.org/10.1111/j.1747-0285.2009.00840.x>
- Degnan, J. J., & Field, C. T. (2014). Moderate to high altitude, single photon sensitive, 3D imaging lidars. *Advanced Photon Counting Techniques VIII*, 9114, 91140H. <https://doi.org/10.1117/12.2049995>
- Dietterich, T. G. (2000). Ensemble methods in machine learning. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1857 LNCS, 1–15.

- Dönmez, P. (2012). Introduction to Machine Learning, Wikipedia Guide. *Natural Language Engineering*, 19(02), 285–288. <https://doi.org/10.1017/S1351324912000290>
- ESRI. (2014). LAS Optimizer 1.2. Retrieved July 16, 2019, from <https://www.arcgis.com/home/item.html?id=787794cdbc384261bc9bf99a860a374f>
- Friedman, J. H. (1999). Greedy Function Approximation: A Gradient Boosting Machine. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/https://dl.acm.org/citation.cfm?doid=2939672.2939785>
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3–42. <https://doi.org/10.1007/s10994-006-6226-1>
- Henn, A., Gröger, G., Stroh, V., & Plümer, L. (2013). Model driven reconstruction of roofs from sparse LiDAR point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 76, 17–29. <https://doi.org/10.1016/j.isprsjprs.2012.11.004>
- Hyyppä, J. (2011). State of the art in laser scanning. *Photogrammetric Week ' 11*, (2008), 203–216.
- IGN. (2019). Plan Nacional de Ortofotografía Aérea. <https://doi.org/10.1080/02699930902958255>
- Isenburg, M. (2013). LASzip: Lossless compression of lidar data. *Photogrammetric Engineering and Remote Sensing*, 79(2), 209–217. <https://doi.org/10.14358/PERS.79.2.209>
- Ivanova, I., & Galo, M. (2017). Quality assessment for automatic LiDAR data classification methods. *Anais Do XVIII Simpósio Brasileiro de Sensoriamento Remoto -SBSR*, 6772–6779.
- Korpela, I., Koskinen, M., Vasander, H., Holopainen, M., & Minkkinen, K. (2009). Airborne small-footprint discrete-return LiDAR data in the assessment of boreal mire surface patterns, vegetation, and habitats. *Forest Ecology and Management*, 258(7), 1549–1566. <https://doi.org/10.1016/j.foreco.2009.07.007>
- Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Paper 1 (20). *Artificial Intelligence Review*, 26, 159–190. <https://doi.org/10.1007/s10462-007-9052-3>
- Krüger, F. (2018). *Activity, Context, and Plan Recognition with Computational Causal Behaviour Models*. Retrieved from https://www.researchgate.net/figure/Confusion-matrix-for-multi-class-classification-The-confusion-matrix-of-a_fig7_314116591
- Leica. (n.d.). *Leica ALS80 AG*. Retrieved from https://w3.leica-geosystems.com/downloads123/zz/airborne/als80/brochures/leica_als80_bro_en.pdf
- Leica. (2017). *Single Photon LiDAR: The logical next step in airborne LiDAR mapping*. Retrieved from ftp://ftp.cartografia.navarra.es/5_LIDAR/_SPL_100.pdf
- Lodha, S. K., Krepes, E. J., Helmbold, D. P., & Fitzpatrick, D. (2007). Aerial LiDAR data classification using Support Vector Machines (SVM). *Proceedings - Third International Symposium on 3D Data Processing, Visualization, and Transmission, 3DPVT 2006*, 567–574. <https://doi.org/10.1109/3DPVT.2006.23>
- Lu, Z., Im, J., Rhee, J., & Hodgson, M. (2014). Building type classification using spatial and landscape attributes derived from LiDAR remote sensing data. *Landscape and Urban Planning*, 130(1), 134–148. <https://doi.org/10.1016/j.landurbplan.2014.07.005>
- Mallet, C., & Bretar, F. (2009). Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1), 1–16.

<https://doi.org/10.1016/j.isprsjprs.2008.09.007>

- National Oceanic and Atmospheric Association. (2012). Lidar 101 : An Introduction to Lidar Technology , Data , and Applications. *NOAA Coastal Services Center*, (November), 1–72. <https://doi.org/10.5194/isprsarchives-XL-7-W3-1257-2015>
- Parlamento Europeo. (2007). Directiva 2007/2/CE del Parlamento Europeo y del Consejo de 14 de marzo de 2007 por la que se establece una infraestructura de información espacial en la Comunidad Europea (Inspire). *Diario Oficial de La Unión Europea*, 1–14. Retrieved from <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2007:108:0001:01:ES:HTML>
- Popescu, S. C., & Zhao, K. (2008). A voxel-based lidar method for estimating crown base height for deciduous and pine trees. *Remote Sensing of Environment*, 112(3), 767–781. <https://doi.org/10.1016/j.rse.2007.06.011>
- Rapidlasso GmbH. (2013). New compressed LAS format by ESRI. Retrieved July 16, 2019, from <https://rapidlasso.com/2013/12/30/new-compressed-las-format-by-esri/>
- Riegl. (2012). *RIEGL LMS-Q680i Airborne Laser Scanning*. Retrieved from http://www.riegl.com/uploads/tx_pxpriegldownloads/10_DataSheet_LMS-Q680i_28-09-2012_01.pdf
- Riegl. (2019). *RIEGL VQ -780i Airborne Laser Scanning*. Retrieved from http://www.riegl.com/uploads/tx_pxpriegldownloads/RIEGL_VQ-780i_Datasheet_2019-07-04.pdf
- Rumelhart, D. E., Hinton, G. E., Williams, R. J., & Others. (1986). Learning Representations by Back Propagation Errors. *Letters to Nature*, 5(3), 533–536.
- Scaioni, M., Höfle, B., Baugarten Kersting, A. P., Barazzetti, L., Previtali, M., & Wujanz, D. (2018). Methods from information extraction from lidar intensity data and multispectral lidar technology. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3), 1503–1510. <https://doi.org/10.5194/isprs-archives-XLII-3-1503-2018>
- Sithole, G., & Vosselman, G. (2004). Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(1–2), 85–101. <https://doi.org/10.1016/j.isprsjprs.2004.05.004>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Swatantran, A., Tang, H., Barrett, T., Decola, P., & Dubayah, R. (2016). Rapid, High-Resolution Forest Structure and Terrain Mapping over Large Areas using Single Photon Lidar. *Scientific Reports*, 2016, 1–12.
- Terrasolid. (2019). Terrasolid Products. Retrieved July 29, 2019, from <http://www.terrasolid.com/products.php>
- Tracasa. (2018). *Segunda cobertura LiDAR de la Comunidad Foral de Navarra*. Retrieved from http://ww2.pcypsitna.navarra.es/Aprende/Documentacin/GeoEuskadi2018_2a_cobertura_LiDAR.pdf
- Vosselman, G., & Mass, H. G. (2010). *Airborne and Terrestrial Laser Scanning* (1st ed.). Dunbeath: Whittles Publishing.
- Wang, C., & Philpot, W. D. (2007). Using airborne bathymetric lidar to detect bottom type

variation in shallow waters. *Remote Sensing of Environment*, 106, 123–135.
<https://doi.org/10.1016/j.rse.2006.08.003>

Wehr, A., & Lohr, U. (1999). Airborne laser scanning - An introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 68–82.
[https://doi.org/10.1016/S0924-2716\(99\)00011-8](https://doi.org/10.1016/S0924-2716(99)00011-8)

Wu, X., Kumar, V., Ross, Q. J., Ghosh, J., Yang, Q., Motoda, H., ... Steinberg, D. (2008). Top 10 algorithms in data mining. In *Knowledge and Information Systems* (Vol. 14).
<https://doi.org/10.1007/s10115-007-0114-2>

6. ANEXOS

6.1. Anexo I: Primera cobertura LiDAR PNOA

Tabla 58. Información detallada de los lotes (Primera cobertura) Fuente: IGN (2019)

Lote	Año de tramitación	Fecha inicio vuelo	Fecha fin vuelo	Densidad (p/m ²)	RMSE xy (m)	RMSE z (m)	Sensor principal	Año color RGB	Año color IrRG
CAT	2008	abr-08	sep-11	0,5	0,3	0,4	LEICA ALS50	2009	2009-2011
CLM SE	2009	jul-09	nov-09	0,5	0,3	0,4	LEICA ALS50	2009	2012
CLM SW	2009	jul-09	oct-09	0,5	0,3	0,4	LEICA ALS50	2009	2012
CLM-CAS	2009	ago-09	oct-09	0,5	0,3	0,4	LEICA ALS60	2009	2012
CLM NW	2009	ago-09	feb-10	0,5	0,3	0,4	LEICA ALS50	2009	2012
CAN	2009	-	-	0,5	0,3	0,4	LEICA ALS50	2009	2012
VAL	2009	ago-09	sep-09	0,5	0,3	0,4	RIEGL LMS-Q680	2010	2012
GAL E	2009	sep-09	oct-09	0,5	0,3	0,4	RIEGL LMS-Q680	2009	2011
MUR-CLM-ALI	2009	oct-09	dic-09	0,5	0,3	0,4	LEICA ALS50	2009	2011-2012
EXT S	2010	oct-09	sep-10	0,5	0,3	0,4	LEICA ALS50	2011	2011
ARA S	2010	ago-10	ene-11	0,5	0,3	0,4	LEICA ALS50	2009	2012
CYL NE-RIO	2010	ago-10	oct-10	0,5	0,3	0,4	LEICA ALS50	2009-2011	2011
CYL-MAD	2010	ago-10	dic-10	0,5	0,3	0,4	LEICA ALS50	2011	2010
EXT N	2010	ago-10	jul-11	0,5	0,3	0,4	LEICA ALS50	2010	2012
ARA N	2010	sep-10	feb-11	0,5	0,3	0,4	LEICA ALS60	2009	2012
CYL NW	2010	oct-10	nov-10	0,5	0,3	0,4	LEICA ALS50	2011	2010
GAL W	2010	feb-11	abr-11	0,5	0,3	0,2	RIEGL LMS-Q680i	2010	2010
NAV	2012	feb-11	jun-12	0,5	0,3	0,2	LEICA ALS60	2012	2008
AST	2012	may-12	oct-12	0,5	0,3	0,2	RIEGL LMS-Q680i	2011	2011
PV	2012	jul-12	ago-12	0,5	0,3	0,2	RIEGL LMS-Q680i	2012	2012
CANT	2012	ago-12	oct-12	0,5	0,3	0,2	RIEGL LMS-Q680i	2014	2010
AND NW	2014	mar-14	may-14	0,5	0,3	0,2	LEICA ALS60	2013	2011
AND NE	2014	mar-14	may-14	0,5	0,3	0,2	LEICA ALS60	2013	2011
BAL	2014	oct-14	nov-14	0,5	0,3	0,2	LEICA ALS60	SIMULTÁNEO	2012
CyL SW	2014	nov-14	jul-15	0,5	0,3	0,2	LEICA ALS60	2014	2011
AND SE	2014	dic-14	ene-15	0,5	0,3	0,2	LEICA ALS60	2016	2010
AND SW	2015	nov-15	may-16	0,5	0,3	0,2	LEICA ALS60	2016	2010

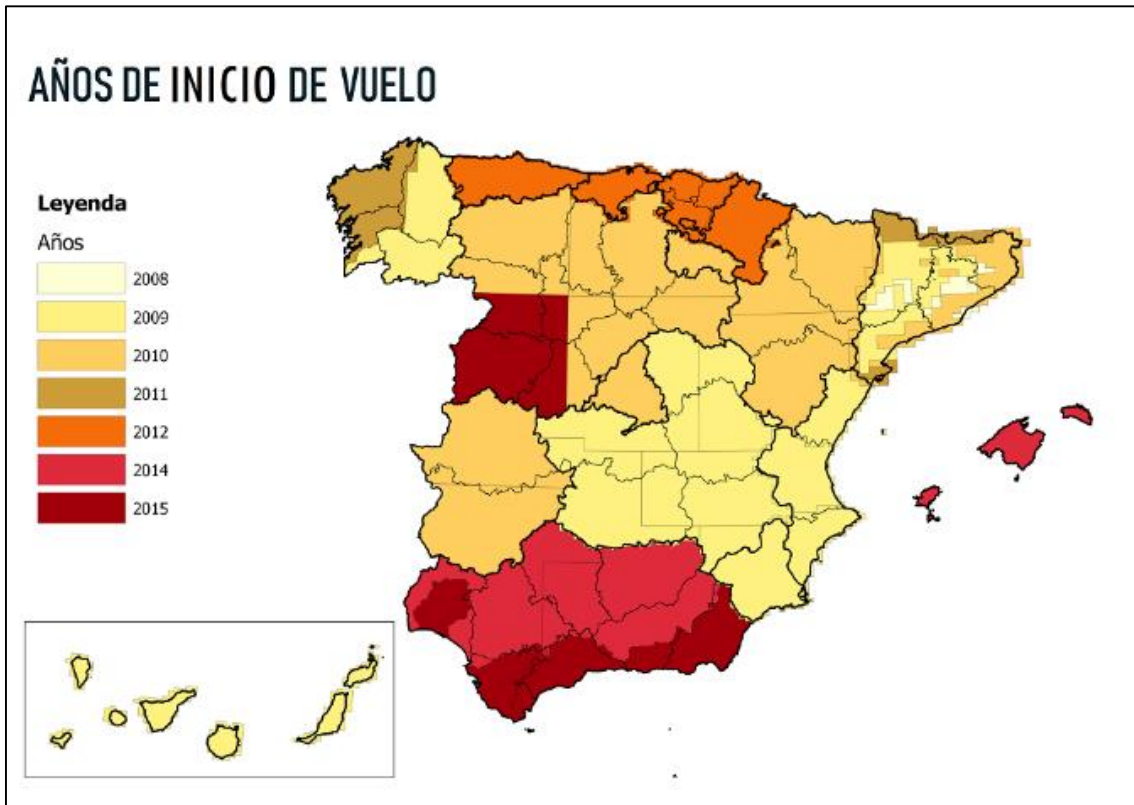


Figura 54. Años de inicio de vuelo de la primera cobertura. Fuente: IGN (2019)

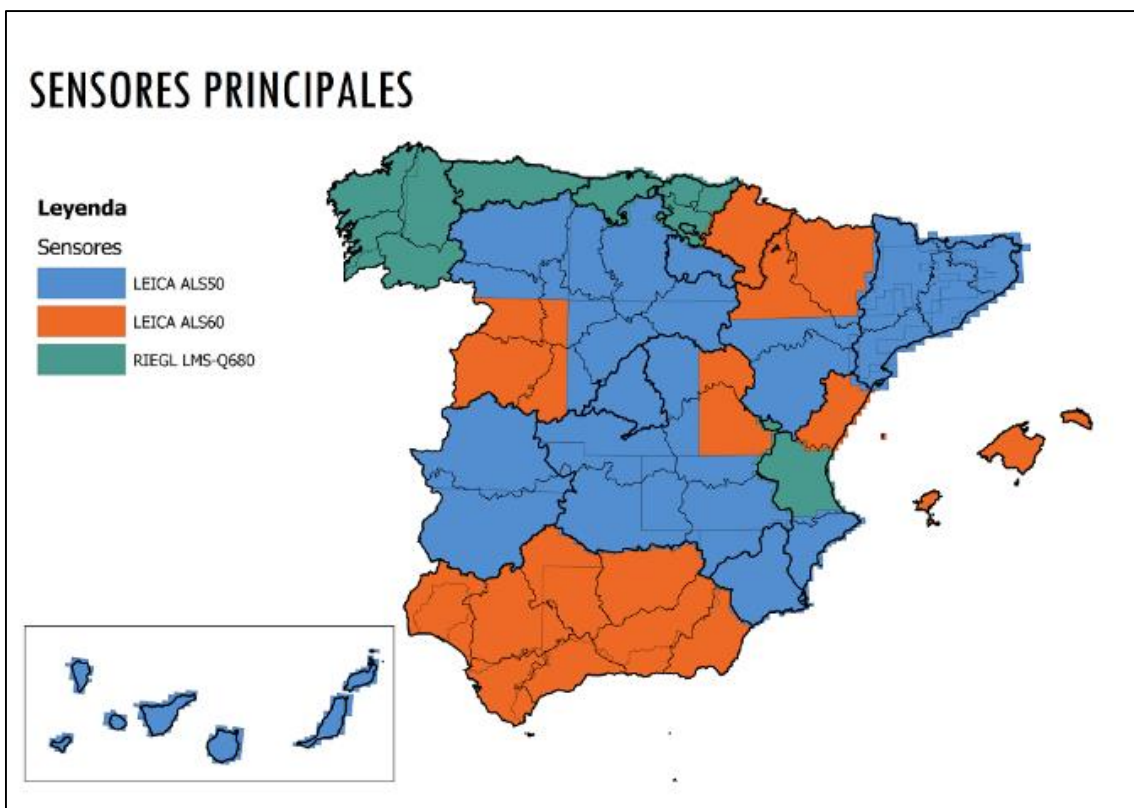


Figura 55. Sensores utilizados en la primera cobertura. Fuente: IGN (2019)



Figura 56. Densidad de puntos por lote en la primera cobertura. Fuente: IGN (2019)

6.2. Anexo II: Segunda cobertura LiDAR PNOA

Tabla 59. Información detallada de los lotes (Segunda cobertura) Fuente: IGN (2019)

ID Lote	Año de tramitación	Fecha inicio vuelo	Fecha fin vuelo	Densidad (p/m ²)	RMSE xy (m)	RMSE z (m)	Sensor principal	Año color RGB	Año color IrRG
GAL W	2015	jul-15	sep-15	0,5	0,3	0,2	LEICA ALS60	2014	2010
VAL	2015	oct-15	nov-15	0,5	0,3	0,2	RIEGL LMS-Q780	SIMULTANEO	2012
CAN	2015	oct-15	feb-17	0,5	0,3	0,2	LEICA ALS60	SIMULTANEO	SIMULTANEO
CAT	2016	abr-16	ago-17	0,5	0,3	0,2	LEICA ALS50	2015	SIMULTANEO
GAL E	2016	ago-16	feb-17	0,5	0,3	0,2	LEICA ALS80	2014	SIMULTANEO
RIO	2016	ago-16	sep-16	2	0,3	0,2	LEICA ALS80	2014	2012
MAD	2016	ago-16	sep-16	1	0,2	0,15	LEICA ALS70-HP	SIMULTANEO	SIMULTANEO
MUR-CLM-ALI	2016	ago-16	mar-17	0,5	0,3	0,2	LEICA ALS60	SIMULTANEO	SIMULTANEO
ARA CN	2016	oct-16	nov-16	1	0,3	0,2	LEICA ALS80	2015	SIMULTANEO
ARA C	2016	oct-16	nov-16	0,5	0,3	0,2	LEICA ALS80	2015	2012
NAV	2017	sep-17	nov-17	14	0,2	0,15	LEICA SPL100	SIMULTANEO	SIMULTANEO
CYL SE	2017	nov-17	dic-18	1	0,2	0,15	-	SIMULTANEO	SIMULTANEO
CLM-CAS	2017	dic-17	nov-18	1	0,2	0,15	LEICA ALS80	SIMULTANEO	2012
CLM SE	2017	dic-17	sep-18	1	0,2	0,15	LEICA ALS80	SIMULTANEO	SIMULTANEO
PV	2017	-	-	2	-	-	RIEGL LMS-Q1560	-	-
ARA SE	2017	sep-18	sep-18	1	0,2	0,15	LEICA ALS80	SIMULTANEO	SIMULTANEO
EXT S	2018	jul-18	abr-19	1	0,2	0,15	LEICA ALS80	SIMULTANEO	SIMULTANEO
EXT N	2018	oct-18	mar-19	2	0,2	0,15	RIEGL LMS-Q1560	SIMULTANEO	SIMULTANEO
CANT	2018	oct-18	jul-19	2	0,2	0,15	RIEGL LMS-Q1560	SIMULTANEO	SIMULTANEO
CyL SW	2019	-	-	4	0,3	0,15	-	SIMULTANEO	SIMULTANEO
CyL NE	2019	-	-	4	0,3	0,15	-	SIMULTANEO	SIMULTANEO
CyL C	2019	-	-	1	0,3	0,15	-	SIMULTANEO	SIMULTANEO
BAL	2019	-	-	1	0,3	0,15	-	SIMULTANEO	SIMULTANEO
CLM SW	2019	-	-	2	0,3	0,15	-	SIMULTANEO	SIMULTANEO
CLM NW	2019	-	-	1	0,3	0,15	-	SIMULTANEO	SIMULTANEO

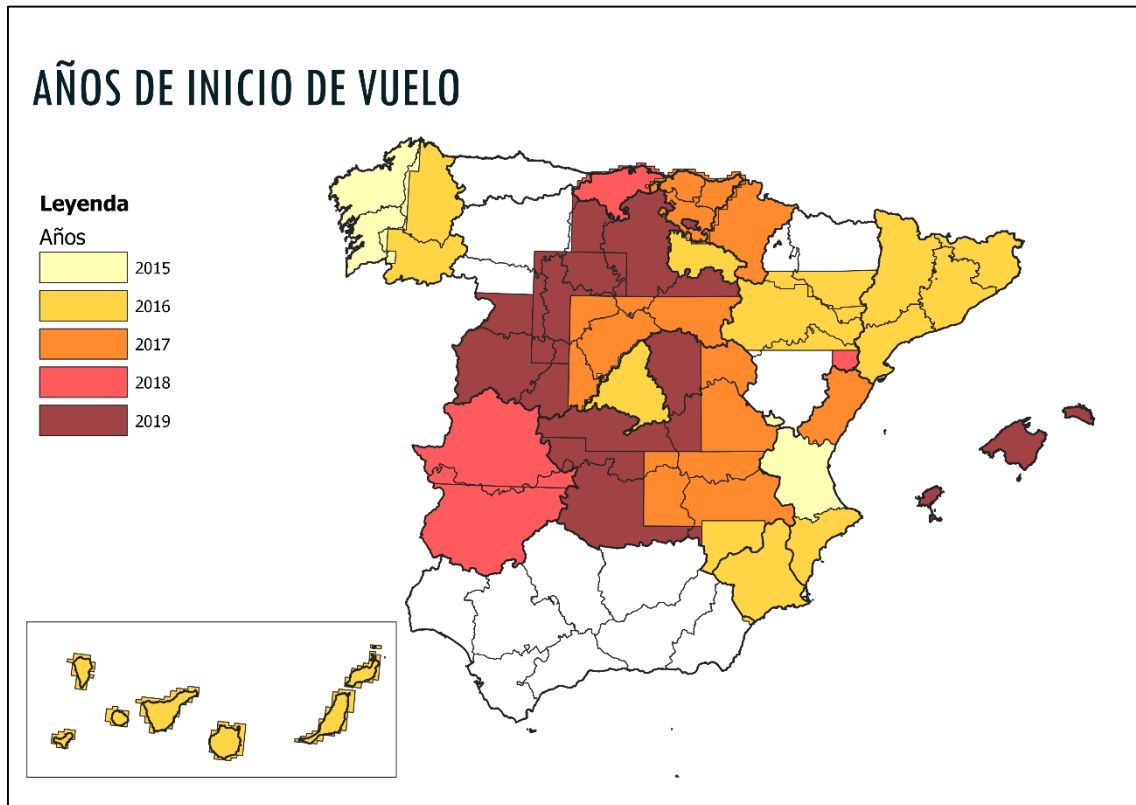


Figura 57. Años de inicio de vuelo de la segunda cobertura. Fuente: IGN (2019)

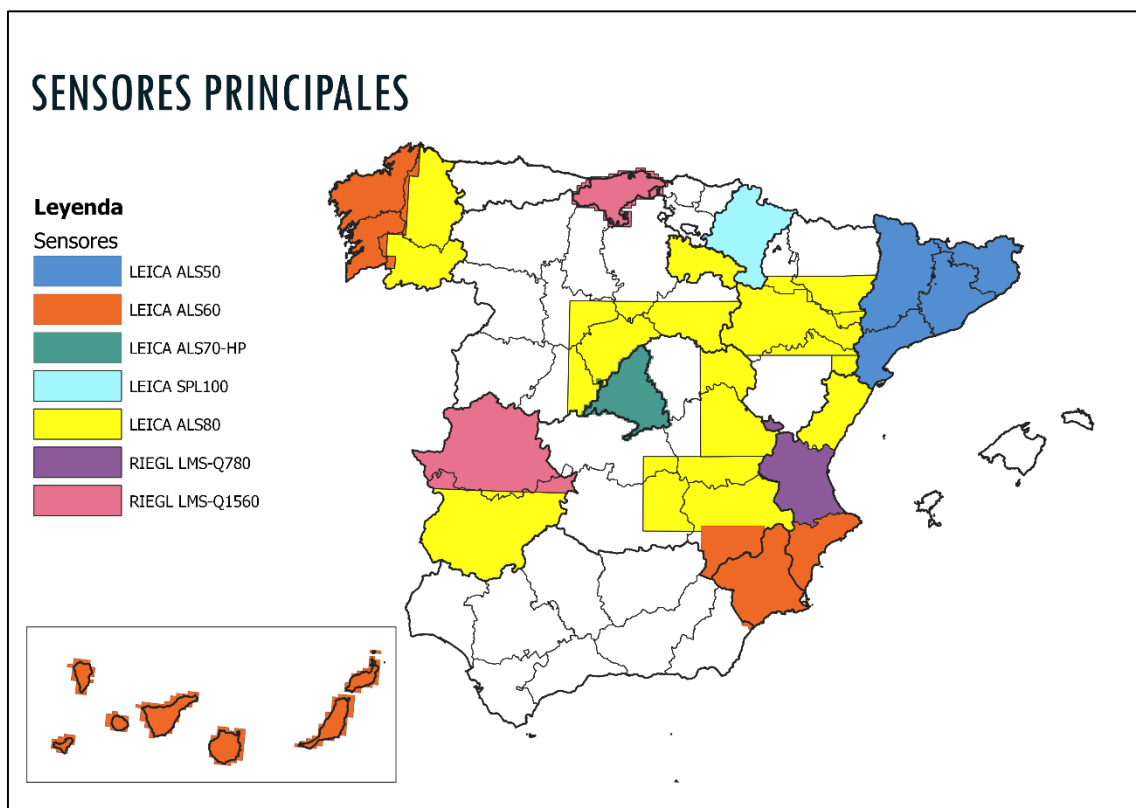


Figura 58. Sensores utilizados en la segunda cobertura. Fuente: IGN (2019)

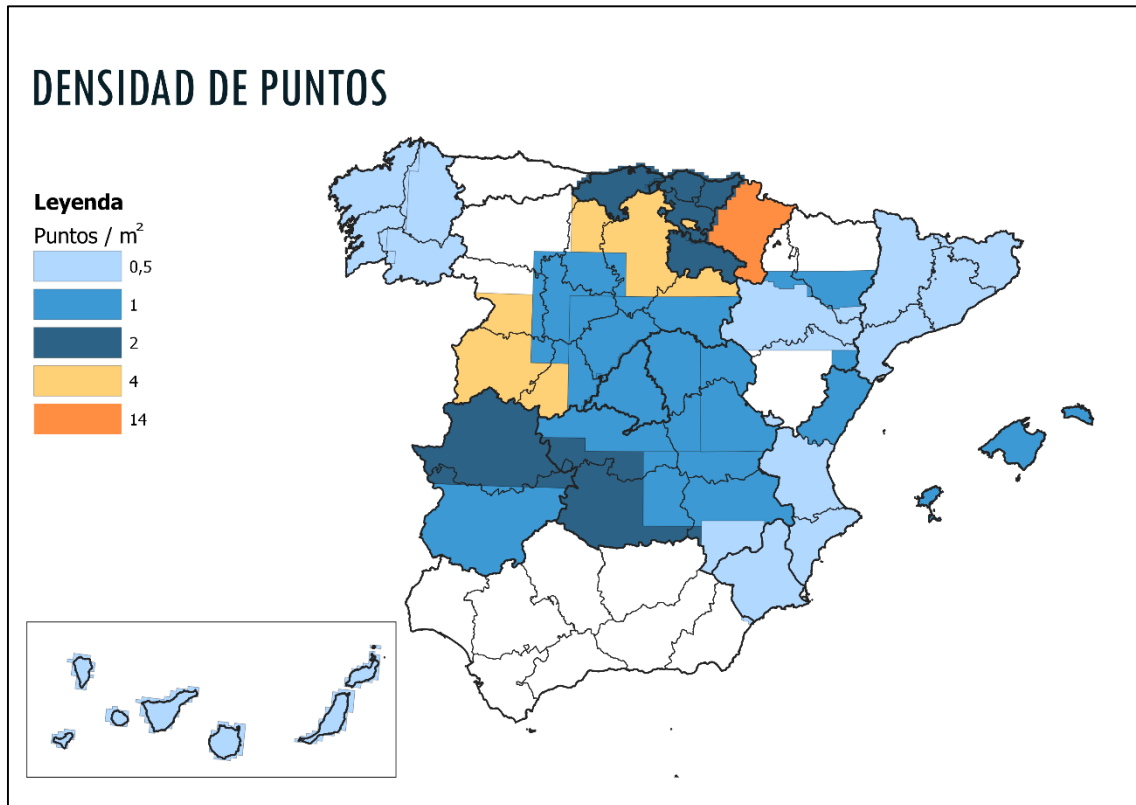


Figura 59. Densidad de puntos de los lotes de la segunda cobertura. Fuente: IGN (2019)

6.3. Anexo III: Mapas de localización de las muestras de entrenamiento y validación




Figura 60. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Galicia Oeste

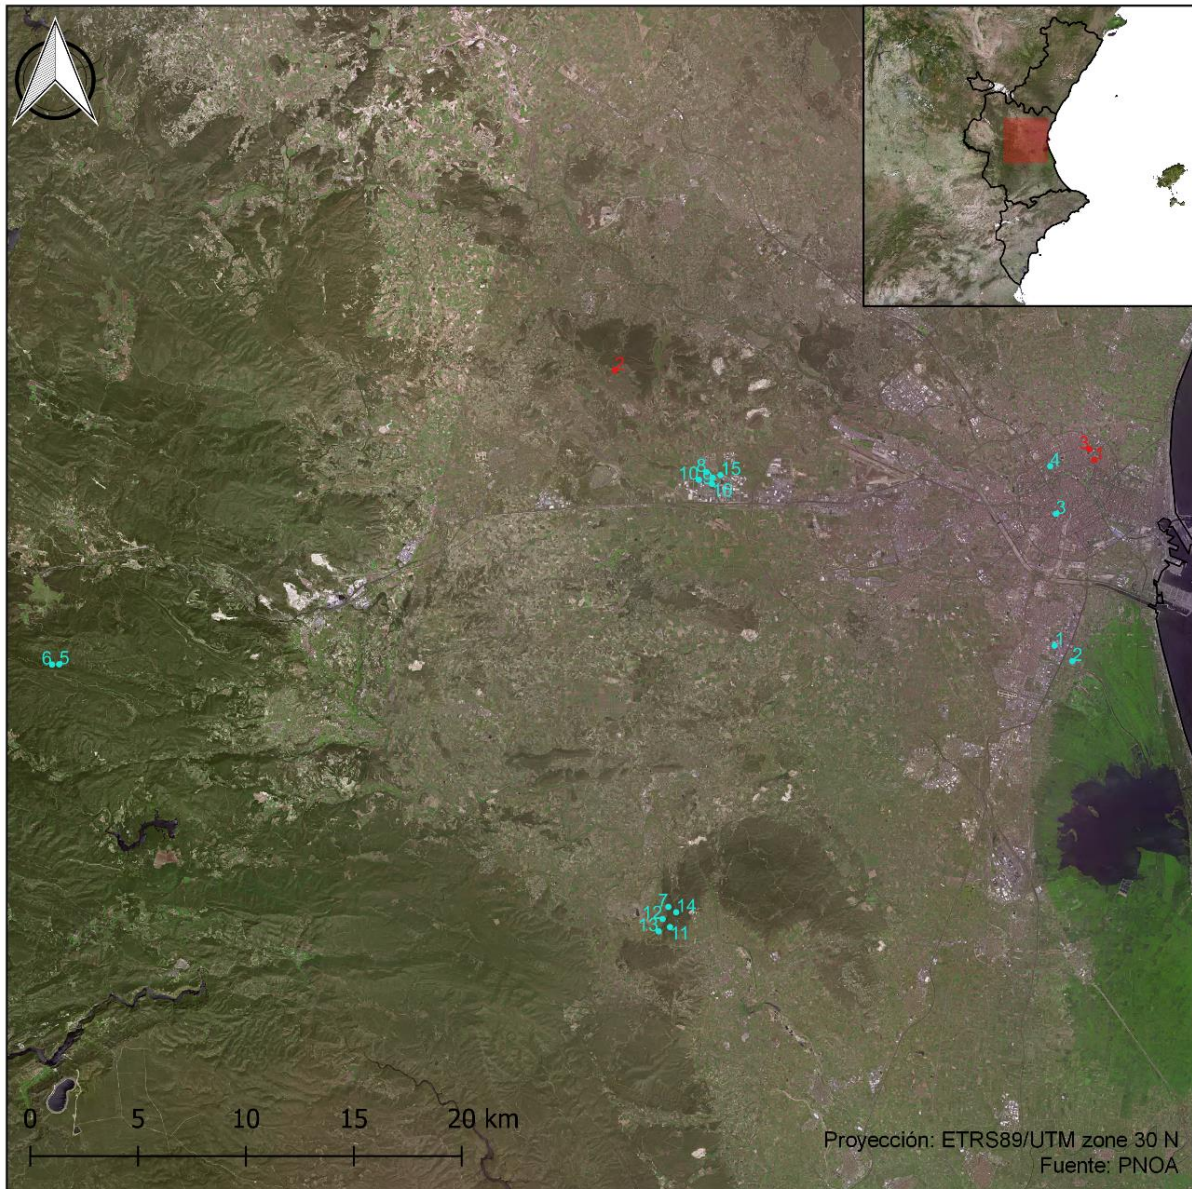


Figura 61. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Valencia (1º cobertura)




Figura 62. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de La Rioja

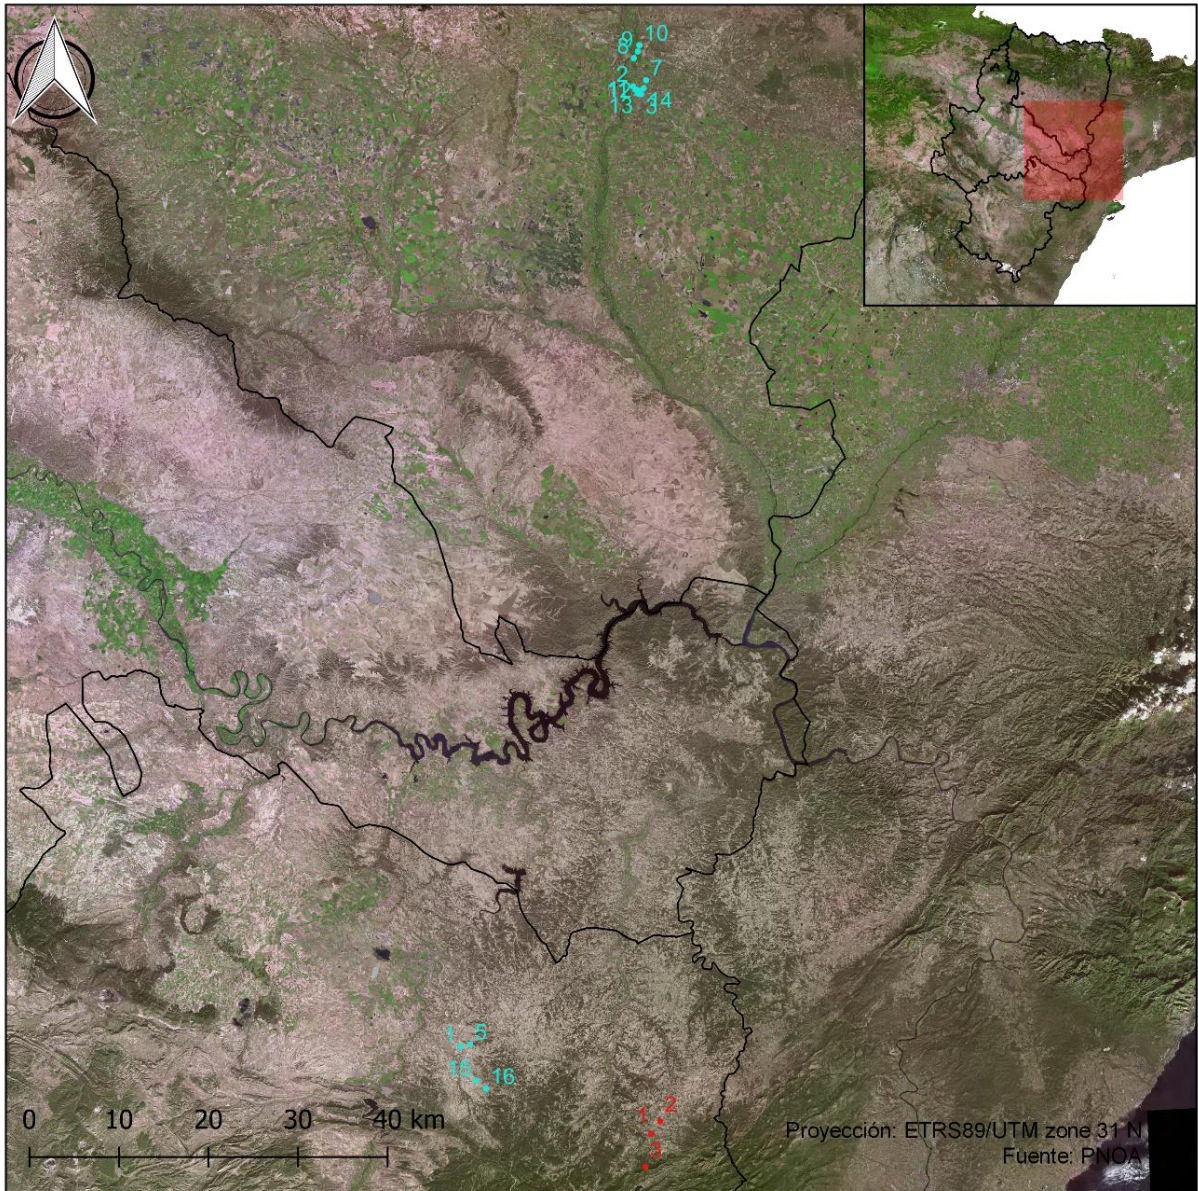


Figura 63. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en los lotes de Aragón CN y Aragón SE

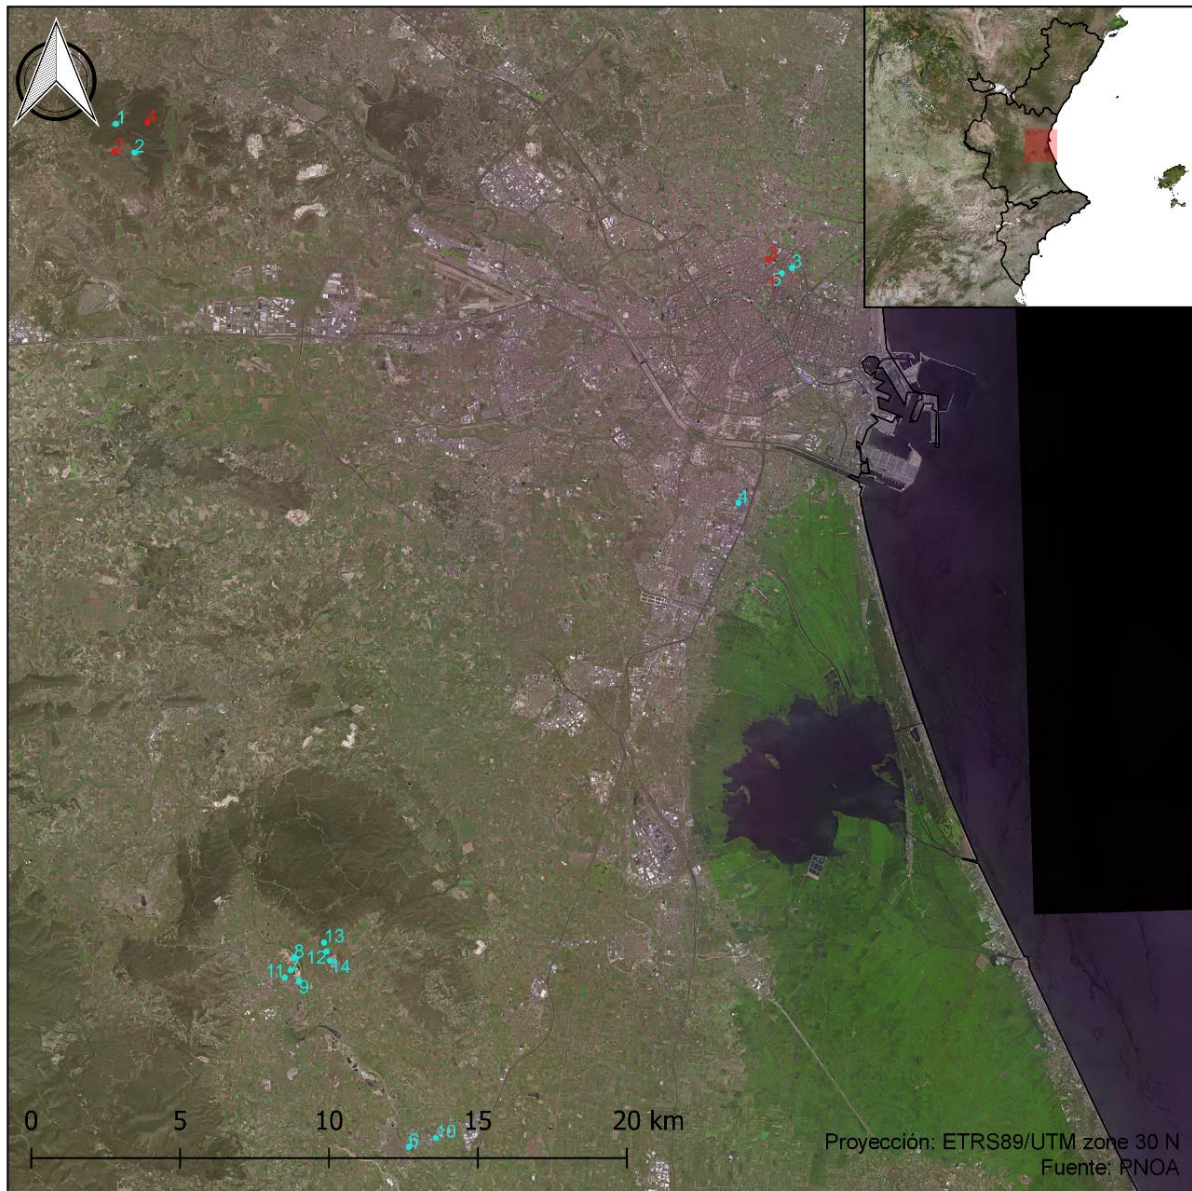


Figura 64. Localización de las muestras de entrenamiento (en azul) y de test (en rojo) en el lote de Valencia (2^o cobertura)

6.4. Anexo IV: Resultados de las clasificaciones

6.4.1. Otros resultados obtenidos del modelo a partir de los datos de ALS80 a 0,5 p/m2 sobre el bloque de referencia

Tabla 60. Tipo de error por clase (en números enteros)

Clase errónea	No problema	Leve	Algo grave	Grave	Muy grave	Total
2	292317	77319	21282	32504	118	423540
3	228421	214581	12504	4483	16	460005
4	6556	21017	8018	40	0	35631
5	10199	28152	15779	217	11	54358
6	1096	46228	77087	55151	204	179766
11	0	0	0	0	0	0
13	542	8536	1726	3	0	10807
Total	539131	395833	136396	92398	349	

Tabla 61. Puntos erróneos de la clase 2 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
2	3	334165	78,90
2	4	51779	12,23
2	5	835	0,20
2	6	36067	8,52
2	11	541	0,13
2	13	154	0,04
		423541	100,00

Tabla 62. Puntos erróneos de la clase 3 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
3	2	337453	73,36
3	4	113912	24,76
3	5	416	0,09
3	6	7321	1,59
3	11	21	0,00
3	13	882	0,19
		460005	100,00

Tabla 63. Puntos erróneos de la clase 4 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
4	2	6795	19,07
4	3	5930	16,64
4	5	11988	33,64
4	6	9266	26,01
4	11	2	0,01
4	13	1650	4,63
		35631	100,00

Tabla 64. Puntos erróneos de la clase 5 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
5	2	318	0,59
5	3	160	0,29
5	4	31553	58,05
5	6	22323	41,07
5	11	0	0,00
5	13	4	0,01
		54358	100,00

Tabla 65. Puntos erróneos de la clase 6 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
6	2	51810	28,82
6	3	6851	3,81
6	4	81294	45,22
6	5	37797	21,03
6	11	0	0,00
6	13	2015	1,12
		179767	100,00

Tabla 66. Puntos erróneos de la clase 11 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
11	2	0	0
11	3	0	0
11	4	0	0
11	5	0	0
11	6	0	0
11	13	0	0
		0	0

Tabla 67. Puntos erróneos de la clase 13 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
13	2	401	3,71
13	3	324	3,00
13	4	8907	82,42
13	5	33	0,31
13	6	1142	10,57
13	11	0	0,00
		10807	100,00

Tabla 68. Matriz de confusión

		Datos predichos							Total
		2	3	4	5	6	11	13	
Datos de referencia	2	5267101	334165	51779	835	36067	541	154	5690642
	3	337453	245790	113912	416	7321	21	882	705795
	4	6795	5930	531569	11988	9266	2	1650	567200
	5	318	160	31553	687102	22323	0	4	741460
	6	51810	6851	81294	37797	351451	0	2015	531218
	11	0	0	0	0	0	0	0	0
	13	401	324	8907	33	1142	0	2046	12853
	Total	5663878	593220	819014	738171	427570	564	6751	

- **Fiabilidad Global:** 0,859
- **Estadístico Kappa:** 0,719

Tabla 69. Error de omisión por clase

Clase	Error omisión
2	0,070
3	0,586
4	0,351
5	0,070
6	0,178
11	1,000
13	0,697

Tabla 70. Error de comisión por clase

Clase	Error comisión
2	0,074
3	0,652
4	0,063
5	0,073
6	0,338
11	0,000
13	0,841

6.4.2. Otros resultados obtenidos del modelo a partir de los datos de Riegl Q-680 a 0,5 p/m² sobre el bloque de referencia

Tabla 71. Tipo de error por clase (en números enteros)

Clase errónea	No problema	Leve	Algo grave	Grave	Muy grave	Total
2	498699	228840	135580	78311	391	941821
3	438	52266	21148	777	7	74636
4	3001	6256	2570	16	0	11843
5	5728	12269	2503	64	11	20575
6	811	180743	396840	185909	1595	765898
11	0	0	0	0	0	0
13	9955	48162	3791	2	0	61910
Total	518632	528536	562432	265079	2004	

Tabla 72. Puntos erróneos de la clase 2 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
2	3	622288	66,07
2	4	227035	24,11
2	5	9281	0,99
2	6	81600	8,66
2	11	446	0,05
2	13	1171	0,12
		941821	100,00

Tabla 73. Puntos erróneos de la clase 3 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
3	2	123	0,16
3	4	72101	96,60
3	5	920	1,23
3	6	1198	1,61
3	11	0	0,00
3	13	294	0,39
		74636	100,00

Tabla 74. Puntos erróneos de la clase 4 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
4	2	70	0,59
4	3	67	0,57
4	5	7957	67,19
4	6	3288	27,76
4	11	0	0,00
4	13	461	3,89
		11843	100,00

Tabla 75. Puntos erróneos de la clase 5 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
5	2	68	0,33
5	3	19	0,09
5	4	15777	76,68
5	6	4675	22,72
5	11	0	0,00
5	13	36	0,17
		20575	100,00

Tabla 76. Puntos erróneos de la clase 6 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
6	2	173999	22,72
6	3	23160	3,02
6	4	123545	16,13
6	5	441630	57,66
6	11	3	0,00
6	13	3556	0,46
		765903	100,00

Tabla 77. Puntos erróneos de la clase 11 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
11	2	0	0
11	3	0	0
11	4	0	0
11	5	0	0
11	6	0	0
11	13	0	0
		0	0

Tabla 78. Puntos erróneos de la clase 13 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
13	2	610	0,99
13	3	644	1,04
13	4	59520	96,14
13	5	690	1,11
13	6	446	0,72
13	11	0	0,00
		61910	100,00

Tabla 79. Matriz de confusión

		Datos predichos							Total
		2	3	4	5	6	11	13	
Datos de referencia	2	5459026	622288	227035	9281	81600	446	1171	6400847
	3	123	669	72101	920	1198	0	294	75305
	4	70	67	300330	7957	3288	0	461	312173
	5	68	19	15777	299062	4675	0	36	319637
	6	173999	23160	123545	441630	304295	3	3556	1070193
	11	0	0	0	0	0	0	0	0
	13	610	644	59520	690	446	0	9101	71011
	Total	5633896	646847	798308	759540	395502	449	14629	

- **Fiabilidad Global:** 0,772
- **Estadístico Kappa:** 0,501

Tabla 80. Error de omisión por clase

Clase	Error omisión
2	0,031
3	0,999
4	0,624
5	0,606
6	0,231
11	1,000
13	0,377

Tabla 81. Error de comisión por clase

Clase	Error comisión
2	0,147
3	0,991
4	0,038
5	0,064
6	0,716
11	0,000
13	0,872

6.4.3. Otros resultados obtenidos del modelo generalista de clasificación sobre el bloque de referencia.

Tabla 82. Tipo de error por clase (en números enteros)

Clase errónea	No problema	Leve	Algo grave	Grave	Muy grave	Total
2	370841	121538	41851	33214	66	567510
3	46311	37241	4529	2972	10	91063
4	11259	33194	8641	105	0	53199
5	6312	13734	11900	80	3	32029
6	1155	58232	76940	54798	276	191401
11	3	6	0	0	0	9
13	1172	4562	432	2	0	6168
Total	437053	268507	144293	91171	355	

Tabla 83. Puntos erróneos de la clase 2 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
2	3	439596	77,46
2	4	89248	15,73
2	5	945	0,17
2	6	36944	6,51
2	11	559	0,10
2	13	218	0,04
		567510	100,00

Tabla 84. Puntos erróneos de la clase 3 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
3	2	48471	53,23
3	4	37868	41,58
3	5	167	0,18
3	6	4380	4,81
3	11	3	0,00
3	13	174	0,19
		91063	100,00

Tabla 85. Puntos erróneos de la clase 4 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
4	2	6817	12,81
4	3	9933	18,67
4	5	23468	44,11
4	6	10218	19,21
4	11	2	0,00
4	13	2761	5,19
		53199	100,00

Tabla 86. Puntos erróneos de la clase 5 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
5	2	123	0,38
5	3	40	0,12
5	4	15297	47,76
5	6	16524	51,59
5	11	0	0,00
5	13	45	0,14
		32029	100,00

Tabla 87. Puntos erróneos de la clase 6 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
6	2	50189	26,22
6	3	9593	5,01
6	4	60216	31,46
6	5	68973	36,04
6	11	0	0,00
6	13	2432	1,27
		191403	100,00

Tabla 88. Puntos erróneos de la clase 11 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
11	2	8	100
11	3	0	0
11	4	0	0
11	5	0	0
11	6	0	0
11	13	0	0
		8	100

Tabla 89. Puntos erróneos de la clase 13 respecto a las otras clases

Clase errónea	Clase correcta	Número de puntos	% total
13	2	141	2,29
13	3	165	2,68
13	4	5519	89,48
13	5	2	0,03
13	6	341	5,53
13	11	0	0,00
		6168	100,00

Tabla 90. Matriz de confusión

		Datos predichos							
		2	3	4	5	6	11	13	Total
Datos de referencia	2	5545577	439596	89248	945	36944	559	218	6113087
	3	48471	141349	37868	167	4380	3	174	232412
	4	6817	9933	613034	23468	10218	2	2761	666233
	5	123	40	15297	650513	16524	0	45	682542
	6	50189	9593	60216	68973	356308	0	2432	547711
	11	8	0	0	0	0	2	0	10
	13	141	165	5519	2	341	0	1003	7171
	Total	5651326	600676	821182	744068	424715	566	6633	

- **Fiabilidad Global:** 0,886
- **Estadístico Kappa:** 0,758

Tabla 91. Error de omisión por clase

Clase	Error omisión
2	0,019
3	0,765
4	0,254
5	0,126
6	0,161
11	0,997
13	0,849

Tabla 92. Error de comisión por clase

Clase	Error comisión
2	0,093
3	0,392
4	0,080
5	0,047
6	0,349
11	0,800
13	0,860